



Ressources naturelles  
Canada

Natural Resources  
Canada

**GÉOMATIQUE CANADA  
DOSSIER PUBLIC 49**

**Revue de littérature sur le potentiel de l'imagerie satellitaire  
optique haute résolution pour l'extraction d'informations  
cartographiques**

**M. Turgeon-Pelchat**

**2019**

**Canada**

# **Revue de littérature sur le potentiel de l'imagerie satellitaire optique haute résolution pour l'extraction d'informations cartographiques**

**M. Turgeon-Pelchat<sup>1</sup>**

<sup>1</sup>Ressources naturelles Canada, 50 Place de la Cité, local 212, C.P.162, Sherbrooke, Québec J1H 4G9

**2019**

© Sa Majesté la Reine du chef du Canada, représentée par le ministre des Ressources naturelles, 2019

Le contenu de cette publication ou de ce produit peut être reproduit en tout ou en partie, et par quelque moyen que ce soit, sous réserve que la reproduction soit effectuée uniquement à des fins personnelles ou publiques mais non commerciales, sans frais ni autre permission, à moins d'avis contraire.

On demande seulement :

- de faire preuve de diligence raisonnable en assurant l'exactitude du matériel reproduit;
- d'indiquer le titre complet du matériel reproduit et le nom de l'organisation qui en est l'auteur;
- d'indiquer que la reproduction est une copie d'un document officiel publié par Ressources naturelles Canada (RNCAN) et que la reproduction n'a pas été faite en association avec RNCAN ni avec l'appui de celui-ci.

La reproduction et la distribution à des fins commerciales sont interdites, sauf avec la permission écrite de RNCAN. Pour de plus amples renseignements, veuillez communiquer avec RNCAN à [rncan.copyrightdroitdauteur.rncan@canada.ca](mailto:rncan.copyrightdroitdauteur.rncan@canada.ca).

Lien permanent : <https://doi.org/10.4095/314735>

On peut télécharger cette publication gratuitement à partir de GEOSCAN (<https://geoscan.rncan.gc.ca/>).

## **Notation bibliographique conseillée**

Turgeon-Pelchat, M., 2019. Revue de littérature sur le potentiel de l'imagerie satellitaire optique haute résolution pour l'extraction d'informations cartographiques; Géomatique Canada, Dossier public 49, 66 p.  
<https://doi.org/10.4095/314735>

Les publications de cette série ne sont pas révisées; elles sont publiées telles que soumises par l'auteur.

## Table des matières

Liste des tableaux.....	IV
Liste des équations.....	IV
Liste des acronymes.....	V
1 Introduction.....	1
2 Extraction des bâtiments.....	2
2.1 Méthodes utilisant l'imagerie optique.....	2
2.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur.....	9
2.3 Applications opérationnelles.....	13
3 Extraction de l'hydrographie.....	14
3.1 Méthodes utilisant l'imagerie optique.....	14
3.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur.....	23
3.3 Applications opérationnelles.....	26
4 Extraction des routes.....	27
4.1 Méthodes utilisant l'imagerie optique.....	27
4.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur.....	34
4.3 Applications opérationnelles.....	37
5 Extraction de la végétation urbaine.....	38
5.1 Méthodes utilisant l'imagerie optique.....	38
5.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur.....	44
5.3 Applications opérationnelles.....	47
6 Conclusion sur les méthodes d'extraction.....	48
7 Bibliographie.....	50
Annexe I - Compendium des méthodes.....	55
Concepts généraux.....	55
Apprentissage automatique - <i>Machine Learning</i> .....	57
Bibliographie du compendium.....	60

## Liste des tableaux

Tableau 2.1 - Synthèse des méthodes d'extraction des bâtiments utilisant l'imagerie optique. ....	7
Tableau 2.2 - Synthèse des méthodes d'extraction des bâtiments utilisant l'imagerie optique combinée à un autre capteur.....	12
Tableau 3.1 - Résultats agrégés des tests de Xie <i>et al.</i> (2016).....	18
Tableau 3.2 - Synthèse des méthodes d'extraction de l'hydrographie utilisant l'imagerie optique. ....	21
Tableau 3.3 - Synthèse des méthodes d'extraction de l'hydrographie utilisant l'imagerie optique combinée à un autre capteur.....	25
Tableau 4.1 - Comparaison des résultats de l'extraction des routes (Maboudi <i>et al.</i> , 2016).....	27
Tableau 4.2 - Synthèse des méthodes d'extraction des routes utilisant l'imagerie optique. ....	32
Tableau 4.3 - Synthèse des méthodes d'extraction des routes utilisant l'imagerie optique combinée à un autre capteur.....	36
Tableau 5.1 - Synthèse des méthodes d'extraction de la végétation urbaine utilisant l'imagerie optique. ....	42
Tableau 5.2 - Synthèse des méthodes d'extraction de la végétation urbaine utilisant l'imagerie optique combinée à un autre capteur. ....	46

## Liste des équations

Équation 3.1 - NDWI (McFeeters, 1996). ....	14
Équation 3.2 - NSVDI (Li <i>et al.</i> , 2014). ....	16
Équation 3.3 –HRWI (Yao <i>et al.</i> , 2015). ....	17
Équation 5.1 - NDVI (Rouse <i>et al.</i> , 1974). ....	38
Équation 5.2 - <i>Green leaf index</i> (Gobron <i>et al.</i> , 2000). ....	39
Équation 1 - Chi carré (adapté de Hopkins, 2017).....	56
Équation 2 - Kappa (adapté de Campbell et Wynne, 2011).....	56

## Liste des acronymes

<b>ACO</b>	Ant colony Optimisation	<b>MNS</b>	Modèle numérique de surface
<b>ACP</b>	Analyse par composante principale	<b>MNT</b>	Modèle numérique de terrain
<b>ANN</b>	Réseau de neurones artificiels	<b>MSAVI</b>	Modified Soil Adjusted Vegetation Index
<b>AWEI</b>	Automated Water Extraction Index	<b>MSI</b>	Morphological Shadow Index
<b>BDG</b>	Base de données géospatiales	<b>NDVI</b>	Normalized Difference Vegetation Index
<b>BDTQ</b>	Base de données topographiques du Québec	<b>NDWI</b>	Normalized difference water index
<b>BSP</b>	Binary Space Partitioning	<b>NGRDI</b>	Normalized Green Red Difference Index
<b>CCCOT</b>	Centre canadien de cartographie et d'observation de la terre	<b>nMNS</b>	Modèle numérique de surface normalisé
<b>ConvNet</b>	Réseau de neurones convolutifs (Convolutional network)	<b>NSVDI</b>	Normalized Saturation-Value Index
<b>CRIM</b>	Centre de recherche informatique de Montréal	<b>OSM</b>	Open Street Map
<b>DMP</b>	Differential morphological profile	<b>OTB</b>	Orfeo ToolBox
<b>FLST</b>	Fast Level Set Transform	<b>PIR</b>	Proche infra-rouge
<b>GAN</b>	General adaptive neighborhood	<b>PSO</b>	Particle Swarm Optimisation
<b>GLI</b>	Green Leaf Index	<b>RADAR</b>	Radio Detection and Ranging
<b>HR</b>	Haute résolution	<b>RNCan</b>	Ressources naturelles Canada
<b>HRWI</b>	High Resolution Water Index	<b>RSO</b>	RADAR à synthèse d'ouverture
<b>HSV</b>	Hue-Saturation-Valeur	<b>RVB</b>	Rouge – Vert - Bleu
<b>IDW</b>	Inverse de la distance pondéré	<b>SOM</b>	Self-Organizing Map
<b>LiDAR</b>	Light Detection and Ranging	<b>SVM</b>	Support vecteur machine
<b>MLC</b>	Maximum likelihood (Maximum de vraisemblance)	<b>TGI</b>	Triangular Greenness Index
<b>MNDWI</b>	Modified Normalized difference water index	<b>TIN</b>	Triangulated irregular Network
<b>MNE</b>	Modèle numérique d'élévation		

# 1 Introduction

L'extraction d'informations cartographiques à partir d'imagerie satellitaire optique est un domaine d'application de la télédétection documenté depuis longtemps. Les technologies et les méthodes évoluent constamment, tout comme la quantité et la qualité des images disponibles. L'arrivée éventuelle d'imagerie satellitaire optique haute résolution (HR), pour l'ensemble des ministères fédéraux, offrira une couverture nationale ainsi que des mises à jour annuelles pour certaines régions du Canada. La disponibilité de ces images offrira une foule de possibilités d'analyses, de traitements et d'extractions d'informations. Le présent rapport documente, en s'appuyant sur la littérature scientifique, les méthodes et les applications opérationnelles qui concernent l'extraction d'informations cartographiques avec l'imagerie optique HR. Le but de ce rapport est d'établir le potentiel de l'imagerie pour l'extraction afin de prioriser les efforts de développement, recenser les limitations et surtout connaître l'état des connaissances actuelles sur le sujet. Il est à noter que le présent rapport se veut un exercice non exhaustif. De plus, le terme haute résolution fait référence aux images dont la résolution spatiale varie de 0,5 à 2,0 m (Navulur, 2007).

Les sections 2 à 5 contiennent la présentation des méthodes selon les différentes thématiques. Ces thématiques ont été sélectionnées pour assurer la continuité des projets d'extraction en cours et par rapport à leur alignement avec les priorités du Centre canadien de cartographie et d'observation de la Terre (CCCOT). Les quatre thématiques d'extractions choisies sont les bâtiments, l'hydrographie, le réseau routier et la végétation urbaine.

## 2 Extraction des bâtiments

La présente section recense et synthétise des méthodes d'extraction des bâtiments. Cette section est divisée en trois : la revue des recherches utilisant seulement l'imagerie optique pour faire l'extraction, les recherches effectuées en combinant l'imagerie optique avec un autre type de capteur, soit le *Light Detection and Ranging* (LiDAR) ou le *Radio Detection and Ranging* (RADAR), et les applications opérationnelles liées à l'extraction des bâtiments.

### 2.1 Méthodes utilisant l'imagerie optique

Différentes méthodes existent pour extraire les bâtiments à partir d'imagerie HR. La présente revue est principalement basée sur celle de Dubois (2014). La plupart des articles cités par Dubois (2014) se retrouvent aussi dans la revue faite par Ghanae *et al.* (2016). Quelques articles ont été ajoutés afin d'offrir un tour d'horizon plus complet et à jour des méthodes d'extraction des bâtiments. Le tableau 2.1, en fin de section, fait la synthèse des études et des résultats de chacune des études décrites dans la présente section.

#### **Méthode basée sur la détection des arêtes des bâtiments**

Jin et Davis (2005) utilisent le *Differential morphological profile* (DMP) pour détecter les bâtiments. Le DMP permet de détecter les formes ou structures dans une image de taille variable (Jin et Davis, 2005). La détection d'arêtes est effectuée soit par la structure du bâtiment en elle-même ou par la détection de l'ombrage (contexte) du bâtiment. Il s'agit d'un processus itératif qui, à chaque itération, raffine la détection de l'arête pour ultimement former le contour du bâtiment. L'algorithme a été amélioré en ajoutant l'extraction en fonction de la signature spectrale des bâtiments. Le produit final de cette méthode combine trois techniques d'extraction soit : structurelle, contextuelle et spectrale. L'étude de Jin et Davis est concentrée dans les zones urbaines à cause de la haute densité et de la régularité des bâtiments présents.

#### **Transformée de Hough**

La transformée de Hough permet d'extraire des motifs linéaires ou courbes dans une image (Jung et Schramm, 2004). La transformation détermine, pour chacun des pixels, l'ensemble des équations linéaires qui peuvent

l'expliquer. En imagerie, cette méthode donne d'excellents résultats lors d'extraction de bâtiments de forme rectangulaire ou circulaire (San et Turker, 2010). En contrepartie, les bâtiments de formes complexes ne sont pas détectés par l'algorithme.

### **Formes pouvant être utilisées pour qualifier un bâtiment**

La méthode de Karantzalos et Paragios (2009) utilise une banque de formes pour établir sa recherche. C'est à partir de ces formes que l'algorithme peut trouver les motifs ressemblants dans l'image. À chaque itération, l'algorithme modifie la forme du polygone de recherche pour la faire correspondre à la réalité des motifs trouvés. Le point négatif de cette méthode est que les formes complexes qui ne se retrouvent pas dans la banque de formes ne seront pas détectées. La méthode se distingue des autres par son niveau de bonne représentation des empreintes détectées (90 % et plus). De plus, quelques zones étudiées sont situées dans des régions comportant une végétation importante.

### **Méthode utilisant une segmentation par *mean shift***

Aytekin *et al.* (2011) effectuent la détection des bâtiments par déduction. Les auteurs utilisent un indice de végétation normalisé (NDVI) pour enlever la forêt, des opérations morphologiques pour masquer les routes et une analyse par composante principale (ACP) pour enlever les artéfacts restants. Sur les zones restantes, ils ont appliqué une segmentation *mean shift* pour extraire les bâtiments (Aytekin *et al.*, 2011). La segmentation *mean shift* est expliquée à l'annexe I. La méthode d'Aytekin *et al.* (2011) fonctionne bien peu importe la forme des bâtiments à extraire (Jiang *et al.*, 2008). Aytekin *et al.* (2011) ont obtenu des résultats intéressants, mais très variables entre les différentes zones testées. Dans les quartiers plus grands (environ 30 bâtiments), les résultats sont insatisfaisants (62 %-70 % de bonnes détections) alors que dans les zones plus petites (environ 10 bâtiments), les résultats sont meilleurs (80 %-96 % de bonnes détections). Les zones étudiées sont situées seulement en milieu urbain sur des zones assez restreintes (quartier) avec très peu de végétation. Cet algorithme pourrait être utilisé en milieu rural puisque les mauvaises détections sont causées par les types de toits ainsi que par la présence de stationnements.

## **Stéréogrammétrie**

Cette méthode a été largement utilisée pour numériser manuellement les bâtiments. L'effet de profondeur donne à l'interprète de l'information supplémentaire pour différencier les éléments de l'image. En contrepartie, cette méthode est très exigeante puisqu'elle nécessite plusieurs images d'une même scène et prises à angles différents pour être en mesure de recréer le modèle. De plus, cette méthode est essentiellement manuelle, ce qui limite la portée du travail. L'erreur de détection est du même ordre (environ 85 %) que les autres méthodes présentées ici (Fraser *et al.*, 2002). Une telle approche permet d'extraire la hauteur du bâtiment et du même coup modéliser les bâtiments extraits en 3D (Baillard et Maître, 1999 ; Chen *et al.*, 1996 ; Fradkin, *et al.*, 2001 ; Fraser *et al.*, 2002).

## **Caractéristiques de formes et de textures**

Les meilleurs résultats sont obtenus avec Izadi et Saeedi (2010). Leur méthode utilise, dans un premier temps, une technique de segmentation hiérarchique basée sur l'algorithme de segmentation d'image *mean shift*. Dans un deuxième temps, leur méthode utilise quatre caractéristiques mathématiques des toits de bâtiments. Ces caractéristiques reflètent la symétrie, la différence entre un toit et son voisinage (gazon, rue, ombrage, etc.) et la faible variance à l'intérieur d'une même surface de toit. Ces caractéristiques permettent de donner une probabilité de toit (*rooftopness*) à chacune des régions de chacun des niveaux du *mean shift* hiérarchique. Finalement, les auteurs ont appliqué un processus de recherche itératif qui permet de cibler les régions ayant les meilleures probabilités d'appartenance à la classe « toit » lors de l'extraction finale.

Une autre méthode intéressante est celle proposée par Sirmacek et Unsalan (2011). Ils utilisent un filtre de Gabor pour déterminer les arêtes potentielles des bâtiments. Le filtre de Gabor est un filtre linéaire que l'on applique sur l'image et qui permet l'extraction d'éléments linéaires, selon la direction recherchée. Pour détecter le centre des bâtiments, ils ont ensuite appliqué un algorithme basé sur les probabilités statistiques. Ils ont appliqué cette méthode sur 32 images IKONOS contenant 911 bâtiments.

## **Algorithme utilisant les contours actifs**

Ahmadi *et al.* (2010) ont développé une méthode basée sur les contours actifs pour extraire les bâtiments. Les auteurs ont modifié le modèle de contours actifs développé par Chan et Vese (2001) et l'ont optimisé pour l'extraction automatique des bâtiments. L'initialisation des contours se fait avec une sélection manuelle de deux points de bâtiments et deux points de «non-bâtiment». Les contours initiaux sont ensuite générés automatiquement et disposés régulièrement sur l'image. Leur méthode comprend finalement une étape de généralisation des contours afin de lisser les bordures des bâtiments. Ils ont réussi à extraire 281 des 347 (80 %) bâtiments et 96 % des bâtiments extraits ont une bordure correctement délimitée.

Liasis et Stavrou (2016) ont eux aussi optimisé l'algorithme de Chan et Vese (2001) pour extraire la bordure des bâtiments. Les contours initiaux sont déterminés en utilisant les centroïdes des zones segmentées par un algorithme *k-means*. Le *k-means* est détaillé à l'annexe I. L'algorithme de Liasis et Stavrou (2016) est paramétré par l'étude des histogrammes de l'image en valeurs hue-saturation-valeur (HSV). Les régions de végétations sont identifiées et éliminées en utilisant l'intensité dans la bande verte alors que les zones d'ombres sont éliminées à cause de leur faible intensité dans toutes les bandes. Les centroïdes extraits des regroupements restants sont considérés comme étant des points sur les bâtiments. L'étape suivante est l'application de l'algorithme optimisé de contours actifs. Ils ont ensuite appliqué un filtre morphologique pour éliminer les petits polygones et raffiner le contour des bâtiments. Les auteurs ont mentionné que leur algorithme considère parfois des stationnements comme étant des bâtiments, à cause de leur forme similaire.

### **Algorithme utilisant l'apprentissage automatique (*Deep Learning*)**

La méthode de Yuan (2016) utilise le réseau de neurones convolutifs (ConvNet) pour extraire l'empreinte des bâtiments à partir d'images HR. Les ConvNet sont expliqués à l'annexe I. L'auteur indique que pour l'entraînement de son algorithme 2000 tuiles ont été utilisées ainsi qu'un masque sur les pixels correspondant à autre chose que les bâtiments, pour ces tuiles. Lorsque l'apprentissage est terminé, l'extraction se fait rapidement et facilement sur de très grandes images. Les tests ont été effectués en dehors des sites d'entraînement. L'auteur a aussi extrait les bâtiments de cinq autres villes des États-Unis, sans aucune préparation sur les images ni autre ajustement à son algorithme. Les images utilisées contiennent une multitude

de caractéristiques spectrales et spatiales, de conditions atmosphériques, de capteurs, de conditions d'illuminations et d'architectures de bâtiments. Les résultats, bien que simplement visuels, démontrent un réel potentiel pour cette méthode.

## **Conclusion**

La revue des méthodes démontre que l'extraction des bâtiments à partir d'images HR est largement documentée et les méthodes sont très nombreuses. Les méthodes traditionnelles d'extraction à partir de la signature spectrale donnent de moins bons résultats que les méthodes plus récentes utilisant les caractéristiques de formes et de textures. Les limites technologiques sont de moins en moins une préoccupation lorsque l'on désire traiter de grandes quantités de données. Cela laisse place à de nouvelles méthodes comme l'apprentissage automatique (*Machine Learning*) dont les applications en télédétection montrent des résultats très intéressants. La principale difficulté dans l'extraction des bâtiments à partir d'images satellitaires HR est la forte similitude entre les bâtiments et les non-bâtiments. Plus spécifiquement, les bâtiments sont difficilement différenciables des zones d'ombres et des espaces de stationnement, dont la forme et le contraste sont très semblables aux bâtiments (Ghanea *et al.*, 2016). La littérature montre aussi que l'extraction des bâtiments est souvent traitée lors de la classification de la couverture du sol. En particulier, trois articles en font mention soit Myint *et al.* (2011), Li *et al.* (2016) et Scott *et al.* (2017). Ces trois articles sont présentés dans la section portant sur l'extraction de la végétation urbaine. La méthode proposée par Liasis et Stavrou (2016) se démarque des autres méthodes par sa simplicité, ses excellents résultats, ainsi que la possibilité d'utiliser seulement des images Rouge-Vert-Bleu (RVB). Autrement, la méthode de Yuan (2016) utilisant un ConvNet pour détecter et extraire l'empreinte des bâtiments montre d'excellents résultats, si l'on souhaite mettre en place un algorithme d'apprentissage automatique. Pour ces deux dernières méthodes, leur utilisation semble appropriée autant dans un milieu rural qu'urbain. Le tableau 2.1 fait la synthèse des méthodes d'extraction des bâtiments utilisant l'imagerie optique seulement.

Tableau 2.1 - Synthèse des méthodes d'extraction des bâtiments utilisant l'imagerie optique.

Méthode	Avantages et limites	Automatisation	Maturité	Nombre de bâtiments	PA*	Qualité**
Jin et Davis (2005)	<ul style="list-style-type: none"> <li>- Multispectrale</li> <li>- Résultats décevants</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Peu de paramétrage (seuils)</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Processus complexe à mettre en place</li> <li>- Chaîne de traitement longue</li> </ul>	121	73 %	59 %
San et Turker (2010)	<ul style="list-style-type: none"> <li>- Bâtiments de formes rectangulaire et circulaire seulement</li> <li>- Multispectrale</li> <li>- nMNS nécessaire</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Peu de paramétrage</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Processus peu complexe</li> <li>- Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels</li> </ul>	394	Entre 78 % et 95 %	Entre 67 % et 80 %
Karantzalos et Paragios (2009)	<ul style="list-style-type: none"> <li>- Nécessite de l'information sur les formes à rechercher</li> <li>- Résultats variables</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Demande une connaissance de la forme des bâtiments à rechercher</li> </ul>	<ul style="list-style-type: none"> <li>- Très faible</li> <li>- Les algorithmes sont tous à développer</li> </ul>	Inconnu	Entre 65 % et 98 %	Entre 65 % et 95 %
Aytekin <i>et al.</i> (2011)	<ul style="list-style-type: none"> <li>- Fonctionne bien peu importe la forme du bâtiment à extraire</li> <li>- Multispectrale</li> <li>- Résultats très variables d'une scène à l'autre</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Quelques paramètres simples à déterminer</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels</li> <li>- Processus linéaire</li> </ul>	Inconnu	Entre 62 % et 96 %	Entre 34 % et 66 %
Fraser <i>et al.</i> (2002)	<ul style="list-style-type: none"> <li>- Permet d'extraire en 3D</li> <li>- Paire d'images nécessaire</li> <li>- Travail manuel</li> </ul>	<ul style="list-style-type: none"> <li>- Très faible</li> <li>- Travail manuel</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels</li> <li>- Processus linéaire</li> </ul>	Inconnu	±85 %	Inconnu

Izadi et Saeedi (2010)	<ul style="list-style-type: none"> <li>- Excellents résultats</li> <li>- RVB suffisant</li> <li>- Demande beaucoup de développement</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Aucun paramètre</li> </ul>	<ul style="list-style-type: none"> <li>- Très faible</li> <li>- Arbre de recherche à développer</li> <li>- Caractéristiques de toits à développer à 100 %</li> </ul>	140	97 %	90 %
Sirmacek et Unsalan (2011)	<ul style="list-style-type: none"> <li>- Excellent taux de détection</li> <li>- RVB suffisant</li> <li>- Permet seulement de détecter les centroïdes des bâtiments</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Aucun paramètre</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Algorithme de probabilité statistique à développer seulement</li> </ul>	911	94 %	80 %
Ahmadi <i>et al.</i> (2010)	<ul style="list-style-type: none"> <li>- RVB suffisant</li> <li>- Résultats moyens</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Quelques paramètres</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Chaîne de traitement simple</li> <li>- Mise en place de l'algorithme de contours actifs</li> </ul>	347	80 %	Inconnu
Liasis et Stavrou (2016)	<ul style="list-style-type: none"> <li>- RVB suffisant</li> <li>- Résultats excellents</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Méthode semi-automatique.</li> <li>- Demande l'analyse des histogrammes HSV.</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Chaîne de traitement simple</li> <li>- Mise en place de l'algorithme de contours actifs</li> </ul>	5063	96 %	Inconnu
Yuan (2016)	<ul style="list-style-type: none"> <li>- Excellent taux de succès</li> <li>- Facilement transposable d'un endroit à un autre</li> <li>- RVB suffisant</li> <li>- Demande beaucoup de données d'entraînement</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Variable selon la disponibilité des données d'entraînement</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Outil en libre accès</li> </ul>	1437	89 %	85 %

\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

Où : FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

## 2.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur

Cette section comprend la revue de littérature concernant l'extraction des bâtiments à partir d'images HR combinés à un autre type de données. En 2016, Ressources naturelles Canada (RNC) a mandaté la firme AECOM afin de produire une étude sur l'extraction des objets cartographiques autres que l'élévation à partir de données LiDAR. Ce rapport documente les méthodes et outils d'extraction des bâtiments, du réseau hydrographique, du réseau routier et des lignes de transport d'énergie. Plusieurs extraits de la revue faite par AECOM (2016) sont inclus dans cette section puisque l'exercice de revue de littérature sur ce sujet a déjà été abordé dans leur rapport. Par contre, seuls les articles les plus pertinents de cette revue ont été conservés et des précisions y ont été apportées. Les méthodes d'extraction utilisant l'imagerie et un autre capteur utilisent seulement le LiDAR. La recherche effectuée n'a pas montré de résultats utilisant le RADAR comme autre capteur, pour cette thématique. Les résultats des méthodes présentés dans cette section se retrouvent dans le tableau 2.2, en fin de section.

### Méthodes combinées au nuage de point LiDAR

Sohn et Dowman (2007) ont développé une méthode utilisant le nuage de points LiDAR et une image IKONOS multispectrale. La première étape de leur processus consiste à utiliser un algorithme pour discriminer les points appartenant au sol des autres. Par la suite, les points de végétation sont filtrés à partir du NDVI produit avec l'image IKONOS. Ces étapes permettent d'obtenir seulement les points appartenant aux bâtiments. Pour reconstruire le contour des bâtiments, une enveloppe est appliquée aux points de bâtiments. Leur méthode inclut aussi une extraction des éléments linéaires autour des enveloppes convexes afin de raffiner la délimitation des bâtiments. Le résultat de classification est situé autour de 90 %.

Li *et al.* (2013) ont développé une méthode qui permet d'extraire l'empreinte des bâtiments à partir d'images RVB et de données LiDAR. Les quatre étapes de leur méthode sont : l'intégration des données LiDAR et de l'image, la suppression des points de sol et des points représentant les arbres, la détection grossière de l'empreinte du bâtiment et le raffinement de l'empreinte. Les auteurs ont utilisé un algorithme de détection de

bordure pour trouver les sommets et les segments linéaires des deux types de données afin de déterminer la transformation géométrique optimale qui permet de conjuguer les deux types de données. Pour filtrer les points de sol dans les données LiDAR, les auteurs ont utilisé un *triangulated irregular network* (TIN) adaptatif alors que pour supprimer les points d'arbres, ils ont plutôt utilisé une méthode de croissance de région (*region growing*). L'étape de détection grossière des empreintes est effectuée à partir des données LiDAR et d'un algorithme de détection des bordures. Finalement, les empreintes raffinées sont extraites en combinant les bordures extraites de l'image optique et des données LiDAR. Cette méthode montre un excellent potentiel pour différencier les bâtiments adjacents.

### **Méthodes combinées aux modèles numériques d'élévation (MNE)**

Rottensteiner *et al.* (2007) ont utilisé le LiDAR pour créer un modèle numérique de terrain (MNT) et un modèle numérique de surface (MNS). Pour extraire les bâtiments, ils ont utilisé deux MNS correspondants au premier et dernier retour LiDAR, un MNT et le résultat d'un NDVI extrait d'une image multispectrale. Pour déterminer la probabilité statistique d'appartenance à la classe de bâtiment, ils ont utilisé la théorie Dempster-Shafer de fusion de données à partir de ces quatre informations. La théorie de Dempster-Shafer permet de classifier les éléments, connaissant l'ensemble des classes en fonction des probabilités. L'extrait suivant provient de AECOM (2016) et complète le résumé de la méthode : « *Les auteurs mentionnent que 95 % des bâtiments plus grands que 70 m<sup>2</sup> ont pu être détectés, tandis que ceux inférieurs à 30 m<sup>2</sup> n'ont pu être détectés. Les auteurs mentionnent également que l'ajout de l'imagerie multispectrale à l'algorithme a amélioré la détection des petits bâtiments résidentiels de 20 %.* »

Hermosilla *et al.* (2011) ont comparé deux méthodes combinant le LiDAR et l'imagerie HR. En voici le résumé tiré d'AECOM (2016). « *Une méthode de classification à l'aide de seuils et une classification orientée-objet ont été comparées par Hermosilla et al. (2011). L'approche par seuils a été développée en sélectionnant l'élévation minimum considérée comme faisant partie d'un bâtiment et la présence de végétation identifiée dans l'imagerie. L'approche par classification a utilisé une combinaison de segmentation avec un arbre de décision. Une métrique décrivant l'ombre par rapport aux objets voisins a été utilisée pour obtenir les relations*

*contextuelles. Les algorithmes ont été paramétrés différemment pour fonctionner en zone urbaine, périurbaine et industrielle. La méthode par seuillage est celle qui a le mieux fonctionné. Elle n'utilise que deux paramètres : la hauteur minimum d'un bâtiment et le maximum de réflectance dans le NDVI de l'imagerie. La méthode a bien fonctionné en zone urbaine et industrielle, mais les résultats sont moins probants en banlieue.* » Le résumé produit par AECOM (2016) est assez complet. Il est cependant important d'ajouter que des filtres morphologiques ont été appliqués lors de la méthode par seuillage afin de lisser le résultat de l'extraction des bâtiments.

Le rapport AECOM (2016) fait mention d'une méthode développée par Awrangjeb *et al.* (2012). En voici l'extrait : *« En 2012, Awrangjeb et al. présente une méthode utilisant le MNS normalisé [nMNS] et l'imagerie dans le but de séparer les bâtiments des arbres. Il utilise des seuils d'élévation pour éliminer les buissons et les arbres ainsi que l'entropie et la réflectance de l'imagerie. Une procédure a ensuite été développée pour extraire les bordures. Un histogramme illustrant l'orientation des bordures de bâtiment est ensuite produit afin d'éliminer les faux positifs. »* Il est cependant nécessaire d'y apporter une précision. Pour enlever les arbres, le NDVI a aussi été utilisé, en plus d'un seuil de largeur et d'aire. Cette précision implique que l'utilisation d'une image multispectrale est nécessaire. Les auteurs ont aussi déposé en libre accès le code MATLAB de leur méthode.

## **Conclusion**

Le LiDAR se prête bien à la détection des bâtiments de par sa composante tridimensionnelle. L'alignement et la fusion du LiDAR et de l'imagerie permettent de tirer profit des avantages des deux types de données et ainsi améliorer les résultats de détection et de représentation. L'utilisation combinée des deux types de données permet d'ajouter de l'information spectrale, de texture et de forme à l'élévation précise des données LiDAR et permet ainsi d'avoir un contexte entourant les points LiDAR (Sohn et Dowman, 2007). Une méthode, présentée par Zhou et Qiu (2015), permet d'extraire les bâtiments et la végétation à partir d'imagerie et de données LiDAR. Cette méthode est présentée dans la section portant sur l'extraction de la végétation urbaine. Le tableau 2.2 fait la synthèse des méthodes présentées dans cette section.

Tableau 2.2 - Synthèse des méthodes d'extraction des bâtiments utilisant l'imagerie optique combinée à un autre capteur.

Méthode	Avantages et limites	Automatisation	Maturité	Nombre de bâtiments	PA*	Qualité**
Sohn et Dowman (2007)	- Nécessite une image multispectrale	- Bonne - Peu de paramétrage	- Bonne - Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels	± 100	88 %	80 %
Li <i>et al.</i> (2013)	- Image RVB suffisante - Excellent pour différencier les bordures de bâtiments adjacents - Peu d'information quantitative sur les résultats	- Bonne - Beaucoup de traitements - Quelques paramètres	- Bonne - Chaînage d'algorithmes déjà implanté	Inconnu	95%	Inconnu
Rottensteiner <i>et al.</i> (2007)	- Nécessite une image multispectrale - Bâtiments <30 m <sup>2</sup> impossible à détecter	- Faible - Paramètres variables d'une scène à l'autre	- Bonne - Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels	4159	Entre 87 % et 91 % bâtiments > 30 m <sup>2</sup>	Inconnu
Hermosilla <i>et al.</i> (2011)	- Adapté aux scènes urbaines, périurbaines et industrielles - Nécessite une image multispectrale	- Excellente - Méthode par seuillage demande très peu de paramètres	- Bonne - Chaînage des traitements très facile - Les outils pour accomplir la chaîne de traitement sont implantés dans la plupart des logiciels	Inconnu	Entre 86 % et 98 %	Entre 66 % et 92 %
Awrangjeb <i>et al.</i> (2012)	- Nécessite une image multispectrale	- Bonne - Quelques paramètres	- Excellente - Code disponible en libre accès	950	95 %	91 %

\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

Où : FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

## 2.3 Applications opérationnelles

L'extraction de bâtiments à partir d'imagerie optique HR peut être utilisée dans un contexte d'évaluation de dégâts lors de désastres naturels. Dubois (2014) a utilisé l'extraction automatique des bâtiments pour évaluer les dégâts lors du tremblement de terre en Haïti en 2010. Il a procédé à l'extraction des bâtiments sur des images avant et après un désastre, en utilisant une méthode semblable à celle proposée par Izadi et Saeedi (2010) avant de procéder à la détection de changement pour évaluer l'impact du tremblement de terre. L'auteur a utilisé plusieurs types d'images (Quickbird, GeoEye et IKONOS) en plus de travailler sur des zones assez grandes (contenant jusqu'à 533 bâtiments). Les zones de travaux étaient des zones urbaines denses. Le logiciel Orfeo (OTB) a été utilisé pour réaliser les traitements d'extraction de bâtiments et les caractéristiques des toits ont été modélisées à l'aide d'une machine à vecteur de support (SVM). Une explication des SVM est fournie à l'annexe I.

Shamaoma *et al.* (2006) ont, eux aussi, extrait les bâtiments dans un contexte de désastres naturels. Leur étude utilise la combinaison de données LiDAR et d'imagerie HR pour extraire les bâtiments dans un contexte d'inondations. Le logiciel eCognition a été utilisé pour extraire les bâtiments à partir d'images QuickBird. Le résultat de cette extraction a été fusionné à la classification à partir de données LiDAR afin d'améliorer la délimitation des bâtiments et d'incorporer une élévation à ceux-ci.

Deux applications opérationnelles ont été développées à partir des méthodes citées dans les sections 3.1 et 3.2. La première application est celle de Yuan (2016). Son utilisation est gratuite, mais non destinée à des fins commerciales. L'application peut être téléchargée à partir du lien suivant : <http://jiangyeyuan.com/bldgExt.html>. La deuxième application développée à partir d'une méthode recensée dans la revue est celle de Awrangjeb *et al.* (2012). Leur application nécessite des données LiDAR et des images multispectrales. La méthode a été implantée dans le logiciel gratuit et open source Barista<sup>1</sup>.

---

<sup>1</sup> Lien vers le site du logiciel : <http://www.baristasoftware.com.au/>

## 3 Extraction de l'hydrographie

### 3.1 Méthodes utilisant l'imagerie optique

L'extraction de l'hydrographie à partir d'imagerie satellitaire optique HR est majoritairement basée sur l'utilisation d'indices utilisant les bandes infrarouges d'images multispectrales. Les résultats des méthodes décrites dans la présente section sont comparés dans le tableau synthèse 3.2, en fin de section.

#### Méthodes utilisant seulement les indices d'eau

L'approche la plus populaire de par sa simplicité et sa rapidité de traitement est l'utilisation des indices d'eau. Le *Normalized Difference Water Index* (NDWI) utilise la très faible réflectance de l'eau dans le proche infrarouge pour différencier les pixels d'eau (Yang *et al.*, 2017). L'équation du NDWI s'écrit comme suit (McFeeters, 1996) :

$$NDWI = \frac{Green - NIR}{Green + NIR}$$

Équation 3.1 - NDWI (McFeeters, 1996).

Xu (2006) a dérivé un nouvel indice à partir du NDWI : le *modified* NDWI (MNDWI). La variante de Xu est qu'il utilise l'infrarouge moyen au lieu du proche infrarouge dans l'équation. Selon lui, l'utilisation du proche infrarouge (PIR) dans l'extraction des plans d'eau a pour effet de surestimer la proportion d'eau dans l'image. L'auteur a comparé son algorithme avec celui de McFeeters dans trois secteurs d'une image Landsat. Les résultats de classification sont supérieurs à 99 % dans les trois secteurs, comparativement à 85 %-95 % pour le NDWI. La méthode a été développée pour des images Landsat.

Feyisa *et al.* (2014) ont, quant à eux, utilisé la richesse spectrale du satellite Landsat 5 en développant un indice d'eau dont le calcul utilise cinq bandes de l'image. Leur algorithme, nommé *Automated Water Extraction Index* (AWEI), permet de bien rehausser le contraste entre l'eau et le reste de l'image, minimisant l'effet de l'ombrage. Ils ont aussi comparé les résultats de leur algorithme avec le MNDWI sur plusieurs portions

d'images dans quatre régions du monde. Les résultats montrent que le AWEI a mieux performé dans chacune des scènes de test avec des résultats variant entre 93 % et 98 % contrairement à 89 % et 95 % pour le MNDWI.

En 2015, Zhai *et al.* ont publié un article comparant le NDWI, MNDWI et le AWEI en utilisant des images Landsat-5 et Landsat -8. Bien que leur étude ne propose pas de nouvelle méthode, cet article permet d'obtenir une évaluation objective des algorithmes. Les auteurs ont compilé les résultats en distinguant les zones urbaines des zones rurales. Les résultats ont montré que le MNDWI et le AWEI ont une précision de classification de l'eau assez semblable (96 %-97 %) et que le NDWI est moins performant dans les zones rurales.

### **Méthode combinant le NDWI et le NDVI**

Sun *et al.* (2012) ont, quant à eux, développé deux méthodes pour extraire l'information des images HR. Leur première méthode combine le MNDWI pour extraire l'eau et le NDVI pour qualifier la qualité de l'eau extraite en quatre classes : turbide, claire, verte et autre. Leur deuxième méthode débute par une segmentation orientée-objet de l'image pour regrouper les éléments homogènes. Par la suite, ils appliquent leur approche pixel par pixel de la première méthode pour évaluer le pourcentage d'eau dans chacune des régions segmentées. Les régions contenant plus de 10 % d'eau étaient ensuite classifiées comme « eau ». C'est avec cette dernière méthode qu'ils ont obtenu les meilleurs résultats.

### **Méthodes utilisant des algorithmes de suppression de l'ombrage**

Les algorithmes NDWI, MNDWI et AEWI ont l'avantage d'être rapides et faciles à mettre en place. Cependant, en milieu urbain ces indices ne permettent pas de faire la différence entre l'ombre causée par les bâtiments et les plans d'eau sur des images HR (Yang *et al.*, 2017 ; Yao *et al.*, 2015 ; Xie *et al.*, 2016 ; Massalabi *et al.*, 2004). Plusieurs méthodes ont été développées pour améliorer la détection et la suppression de ces ombrages. On peut regrouper ces méthodes en trois classes soit : classification orientée-objet (Li *et al.*, 2014 ; Yang *et al.*, 2017), classification SVM (Yao *et al.*, 2015) et *Morphological Shadow index* (MSI) (Xie *et al.*, 2016).

Li *et al.* (2014) ont proposé une méthode d'extraction des plans d'eau à partir d'imagerie HR en deux étapes. La première consiste à segmenter l'image à partir des caractéristiques spectrales en combinant le NDWI au *Normalized Saturation-Value Difference Index* (NSVDI). L'équation du NSVDI s'écrit comme suit :

$$NSVDI = \frac{(Saturation - Value)}{(Saturation + Value)}$$

Équation 3.2 - NSVDI (Li *et al.*, 2014).

Dans l'équation précédente, la saturation et la valeur sont des composantes de l'espace couleur HSV. Par la suite, ils ont utilisé la forme des éléments pour classifier et enlever les zones d'ombrages. Les critères pour déterminer les formes d'ombres sont la compacité, l'angle de la géométrie et la symétrie. Le résultat de leur méthode a été comparé qualitativement avec cinq autres méthodes de classification de l'eau, dont le NDWI et deux autres méthodes de classification SVM. Leurs tests ont été réalisés avec cinq images QuickBird. Malheureusement, les résultats quantitatifs ne sont pas dévoilés dans l'article.

Yang *et al.* (2017) ont développé une méthode qui utilise deux équations dérivées du NDWI pour extraire les zones d'eau potentielles. Dans leur première équation, ils ont remplacé la bande verte du NDWI par la bande bleue. Leur deuxième équation remplace la bande verte du NDWI par les valeurs résultantes de l'analyse ACP. Les résultats de leurs équations ont ensuite été combinés. La détection d'ombrage basée sur une approche orientée-objet a été appliquée sur les zones extraites de leur équation. Pour discriminer les zones d'ombres des zones d'eau, les auteurs ont analysé les relations spectrales entre les bandes de l'image sur les zones d'ombres connues et ont produit trois modèles de relations spectrales. Si les objets identifiés avec les équations de la première étape répondent à un des trois modèles, ils sont classifiés comme tels et les autres objets sont des plans d'eau.

Yao *et al.* (2015) ont développé une méthode de suppression des zones d'ombres utilisant le SVM. Contrairement à l'approche orientée-objet, l'algorithme de SVM doit être entraîné, ce qui demande un effort supplémentaire de mise en place. Dans un premier temps, ils ont développé un nouvel indice d'extraction d'eau : le *High Resolution Water Index* (HRWI). L'idée est que le NDWI n'est pas adapté pour distinguer les

zones d'ombres de l'eau pour une image HR. Les paramètres de cet index ont été calculés par classification SVM et l'équation résultante est la suivante :

$$HRWI = 6 * Green - Red - 6,5 * NIR + 0,2$$

Équation 3.3 –HRWI (Yao *et al.*, 2015).

Les résultats obtenus avec cette équation ont montré qu'elle est robuste et utilisable sur plusieurs sites de travail. Par la suite, ils ont utilisé de nouveau un SVM pour générer un modèle prédictif de détection des zones d'ombre. Ce modèle est basé sur deux principes, soit : (1) la différence de valeur de NDWI de l'ombre est pratiquement équivalente à celle des bâtiments autour alors que le NDWI de l'eau est très différent de ce qui l'entoure (sol, végétation) et (2) la réflectance dans la bande verte de l'eau est rapprochée des pixels qui l'entourent. Ce modèle prédictif sert à distinguer les ombres des plans d'eau. Les zones d'ombres extraites ont servi de masque sur le résultat du HRWI pour obtenir les plans d'eau finaux. Les résultats de l'extraction de cette méthode montrent une nette amélioration par rapport au NDWI. Pour les cinq images testées, le kappa varie entre 0,90 et 0,98. L'indice d'évaluation des résultats kappa est décrit à l'annexe I.

### **Méthode adaptée au capteur WorldView-2**

Xie *et al.* (2016) ont voulu tirer profit du potentiel offert par les huit bandes spectrales du capteur WorldView-2. À partir de ces informations, ils ont développé un nouvel algorithme pour extraire les plans d'eau surfaciques. Dans un premier temps, ils calculent le ratio normalisé d'une bande à haute réflectance (*coastal*, bleue, verte et jaune) et d'une bande à basse réflectance (*red-edge*, PIR1 et PIR2) ainsi que de leur moyenne respective. Ils ont calculé chacune des possibilités de ratio (5 hautes réflectances X 4 basses réflectances = 20 ratios possibles) et, pour chacun des pixels de l'image, ils ont utilisé le ratio optimal pour déterminer la présence ou non d'eau. Pour supprimer les zones d'ombre, les auteurs ont utilisé un MSI développé par Huang et Zhang (2012). Le MSI utilise la faible réflectance des ombres ainsi que leur contraste avec les bâtiments adjacents pour détecter les pixels d'ombres. La soustraction du résultat du MSI sur les plans d'eau potentiels de l'étape 1 permet de supprimer les faux positifs causés par l'ombre. Les résultats ont été comparés avec une méthode de classification par maximum de vraisemblance (MLC) ainsi qu'une méthode SVM. Il s'avère que le SVM a

obtenu de meilleurs résultats (kappa entre 0,70 et 0,97) et davantage lorsqu'il était combiné avec le MSI pour supprimer les zones d'ombres. Le tableau 3.1 résume les résultats pour les trois zones testées.

**Tableau 3.1 - Résultats agrégés des tests de Xie *et al.* (2016).**

Méthode	Zone 1 (kappa)	Zone 2 (kappa)	Zone 3 (kappa)
NDWI	0,669	0,966	0,975
NDWI-MSI	0,863	0,977	0,996
MLC	0,503	0,919	0,940
SVM	0,702	0,972	0,951
MLC-MSI	0,827	0,978	0,977
SVM-MSI	0,881	0,982	0,995

#### **Méthode utilisant les contours actifs (*snake*)**

L'extraction des rivières ayant une largeur de plusieurs pixels sur l'image a été abordée par Dillabaugh *et al.* (2002). Leur processus utilise, dans un premier temps, des images multispectrales à résolution moyenne ( $\pm 20$  m) pour extraire les rivières sous forme de lignes. Ces rivières extraites à plus petite échelle servent de ligne de départ dans l'application d'un algorithme de *snake* pour rechercher le contour de la rivière dans l'image panchromatique à haute résolution.

#### **Méthode utilisant le *self organizing map* (SOM)**

Zaremba (2011) présente une méthode utilisant le SOM pour extraire les éléments hydrographiques et générer le réseau hydrographique afin d'obtenir une représentation cartographique adéquate. Dans un premier temps, il a entraîné et utilisé un SOM pour classifier l'image pixel par pixel selon ses caractéristiques spectrales. Le PIR a été majoritairement utilisé pour discriminer l'eau. Le résultat de cette classification est une image binaire des zones d'eau et non-eau. Dans un deuxième temps, un nouveau SOM a été utilisé pour le processus de création du réseau hydrographique à partir du principe de courbe principale. L'auteur ne fait pas mention des résultats obtenus avec sa méthode, mais il indique qu'elle a été appliquée sur des images Spot, QuickBird et Landsat-7. Une description des SOM est fournie à l'annexe I.

#### **Méthodes utilisant la variance et l'intensité d'une image panchromatique**

La méthode de Khurshid et Khan (2012) permet d'extraire automatiquement les rivières à partir d'images panchromatiques. La méthode peut être divisée en deux étapes itératives. La première étape permet de calculer un masque approximatif sur le contour des rivières en utilisant la variance. La deuxième étape permet de raffiner le résultat de l'étape précédente en utilisant les valeurs d'intensité de l'image panchromatique. Les résultats ont montré que la méthode permet d'extraire le contour de la rivière de manière « efficace et détaillée » sans toutefois présenter le tableau des résultats. Les auteurs ont utilisé une image SPOT-5 de 2.5 m de résolution pour tester leur méthode.

Wang *et al.* (2008) ont eux aussi utilisé la variance d'images panchromatiques pour extraire les eaux intérieures de plus de 100 m<sup>2</sup>. Leur processus comporte deux étapes soit : extraction de l'eau basée sur la variance et suppression des faux positifs basés sur la corrélation entre les classes d'eau et le reste. Les tests ont été réalisés sur une image de 1 m de résolution et d'une taille de 6126 X 4800 pixels.

## **Conclusion**

L'utilisation des indices d'eau NDWI et ses dérivés ont été maintes fois utilisés, documentés et testés. Pour des images ayant une résolution spatiale moyenne (5 m-30 m), ces méthodes peuvent être utilisées telles quelles avec d'excellents résultats. Par contre, elles ne peuvent être appliquées seules sur des images optiques HR, particulièrement dans les scènes urbaines. C'est pourquoi plusieurs auteurs mentionnent l'utilisation d'algorithmes de suppression des zones d'ombres subséquentement à l'application des indices utilisant l'information spectrale. Ces méthodes sont simples à mettre en place et très efficaces puisque l'ensemble des résultats des différents articles dépasse 90 % d'exactitude. La méthode de Yao *et al.* (2015) est, parmi les méthodes qui suppriment les zones d'ombres, celle qui représente la meilleure opportunité de développement. Les méthodes de Khurshid et Khan (2012) et de Wang *et al.* (2008) n'utilisent pas l'information multispectrale, semblent très intéressantes et faciles à mettre en place. Dans les deux cas, les auteurs ont mentionné avoir obtenu des résultats intéressants (supérieur à 90 %). Toutefois, les détails de ces résultats ne sont pas mentionnés dans les articles et les auteurs ne font aucune mention de la problématique des zones d'ombrages dans les images HR. À la lumière de la recherche effectuée, aucun article n'a eu recours à l'utilisation de réseau

de neurones artificiel (ANN) ou de ConvNet pour extraire l'hydrographie. Les ANN sont expliqués à l'annexe I. Le tableau 3.2 présente la synthèse des méthodes présentées dans la présente section.

Tableau 3.2 - Synthèse des méthodes d'extraction de l'hydrographie utilisant l'imagerie optique.

Méthode	Avantages et limites	Automatisation	Maturité	UA*	PA**	Qualité*** Kappa****
Xu (2006)	<ul style="list-style-type: none"> <li>- Approche pixel par pixel très simple</li> <li>- Multispectrale (infrarouge moyen)</li> <li>- Méthode développée pour des images Landsat</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Seulement un seuil à déterminer</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Indice facile à implémenter</li> </ul>	Inconnu	Inconnu	99 % 0,99
Feyisa <i>et al.</i> (2014)	<ul style="list-style-type: none"> <li>- Approche pixel par pixel très simple</li> <li>- Multispectrale (infrarouge moyen et proche infrarouge)</li> <li>- Méthode développée pour des images Landsat</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Seulement un seuil à déterminer</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Indice facile à implémenter</li> </ul>	Entre 95 % et 100 %	Entre 91 % et 99 %	Entre 90 % et 99 % Entre 0,95 et 0,98
Sun <i>et al.</i> (2012)	<ul style="list-style-type: none"> <li>- Multispectrale (infrarouge moyen et proche infrarouge)</li> <li>- Ne tient pas compte de l'ombrage de l'imagerie HR</li> <li>- Méthode développée pour des images Landsat</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Quelques seuils à déterminer</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Processus simple à implémenter</li> </ul>	95 %	72 %	99 % 0,81
Li <i>et al.</i> (2014)	<ul style="list-style-type: none"> <li>- Soustraction de l'ombrage</li> <li>- Multispectrale</li> <li>- Manque d'information sur les résultats</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Seuils pour les indices à déterminer</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Indices et opérateurs sur les formes faciles à implémenter</li> </ul>	Inconnu	Inconnu	Inconnu
Yang <i>et al.</i> (2017)	<ul style="list-style-type: none"> <li>- Excellents résultats</li> <li>- Soustraction de l'ombrage</li> <li>- Multispectrale</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Les modèles de relations spectrales sont dépendants de la zone d'extraction</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Processus assez complexe, mais constitué d'algorithmes déjà développés</li> </ul>	Entre 90 % et 99 %	Entre 88 % et 99 %	Entre 97 % et 99 % Entre 0,87 et 0,96
Yao <i>et al.</i> (2015)	<ul style="list-style-type: none"> <li>- Soustraction de l'ombrage</li> <li>- Modèles de détection de l'eau et de l'ombrage indépendant</li> <li>- Excellents résultats</li> </ul>	<ul style="list-style-type: none"> <li>- Excellent</li> <li>- Les paramètres ont déjà été calculés par SVM</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Processus assez simple</li> <li>- Entièrement à développer</li> </ul>	Entre 93 % et 98 %	Entre 88 % et 98 %	Inconnu Entre 0,90 et 0,98

	- <b>Multispectrale</b>					
Xie <i>et al.</i> (2016)	- Soustraction de l'ombrage - Modèles de détection de l'eau et de l'ombrage indépendant - Excellents résultats - <b>Images WV-2 (8 bandes)</b>	- Faible - Nécessite des images WV-2 et ses huit bandes	- Bonne - Beaucoup de traitements, assez simples	Entre 88 % et 99 %	Entre 86 % et 100 %	Inconnu 0,86-0,99
Dillabaugh <i>et al.</i> (2002)	- Panchromatique (HR) et multispectrale (BR) - <b>Résultats peu détaillés</b>	- Excellente - Aucun paramètre	- Bonne - Implémentation du contour actif seulement	Inconnu	Inconnu	Inconnu
Zaremba (2011)	- <b>Multispectrale</b> - <b>Manque d'information sur les résultats</b>	- Bonne - Peu de paramètres, en apparence	- Faible - SOM pour reconstituer le réseau hydrographique à développer	Inconnu	Inconnu	Inconnu
Khurshid et Khan (2012)	- <b>Image RVB suffisante</b> - <b>Manque d'information sur les résultats</b>	- Bonne - Peu de paramètres	- Bonne - Chaine des traitements assez simple	93 %	94 %	Inconnu
Wang <i>et al.</i> (2008)	- <b>Image panchromatique suffisante</b> - <b>Peu de détail sur les résultats</b>	- Bonne - Un seul paramètre	- Excellente - Processus très simple	>90 %	>90 %	Inconnu

\* La précision de l'utilisateur (UA) se définit comme suit :  $100 * \frac{TP}{TP+FP}$

\*\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\*\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

## 3.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur

La présente section recense les méthodes utilisant l'imagerie HR combinée au RADAR ou au LiDAR. L'utilisation combinée de RADAR et d'imagerie HR est un sujet d'intérêt, mais qui ne fait pas l'objet de beaucoup de recherches en extraction d'hydrographie. Les méthodes utilisant le LiDAR sont un peu plus nombreuses. Le tableau 3.3 synthétise les méthodes présentées dans la présente section.

### Méthode combinée au RADAR

Joshi *et al.* (2016) ont fait une revue intéressante qui recense et compare cinquante articles de littérature scientifique traitant de la fusion d'images optiques et RADAR à des fins de cartographie de l'utilisation du sol. De ces articles, seulement quatre utilisent l'imagerie optique avec une résolution spatiale meilleure que quatre mètres. Parmi les quatre articles utilisant l'imagerie HR, deux auteurs n'ont pas indiqué si la fusion des types d'images avait amélioré la qualité des résultats. Les deux articles restants ne traitent pas des thématiques présentées ici. Outre cette revue, la présente recherche n'a pas permis d'identifier d'autres méthodes que celle de Hong *et al.* (2015) qui combine le RADAR et l'imagerie.

Hong *et al.* (2015) ont utilisé une méthode de seuillage basée sur l'amplitude pour déterminer les zones d'eau sur l'image RADAR. Une image Landsat a été classifiée en utilisant un algorithme de maximum de vraisemblance en sept classes d'occupation du sol (urbain, agriculture, forêt, pâturage, terres arides, zones humides et eau). Cette classification a été utilisée simplement pour déterminer le seuil de la méthode par seuillage. Cela a permis d'améliorer significativement le résultat de la classification de l'image RADAR.

### Méthodes combinées au LiDAR

Wu *et al.* (2013) utilisent le LiDAR et l'imagerie aérienne pour extraire les polygones d'eau. Leur méthode consiste, dans un premier temps, à créer un TIN à partir des données LiDAR. Par la suite, une discrimination des triangles d'eau des autres triangles est effectuée. Pour ce faire, les auteurs utilisent un seuillage calculé en fonction de la densité des points et la largeur du cours d'eau à extraire. Les triangles identifiés à l'étape 1 sont superposés à l'imagerie aérienne et une classification par *mean-shift* est

appliquée sur les zones couvertes sur ces triangles afin de raffiner la détection des berges de la rivière. Les auteurs ont indiqué dans leur étude que la méthode proposée pourrait être limitée par la présence de turbidité ou de pollution dans l'eau. Ces conditions font en sorte que le LiDAR n'est pas complètement absorbé par l'eau et la méthode proposée ne serait pas en mesure de discriminer les triangles d'eau.

Zhan *et al.* (2002) ont aussi utilisé la capacité de l'eau à absorber le signal LiDAR pour extraire l'information sur l'hydrographie de surface. Leur méthode sert à extraire les bâtiments, l'hydrographie et les espaces verts afin de cartographier l'utilisation du sol sur une image IKONOS. Le LiDAR est utilisé pour extraire les bâtiments et l'hydrographie alors que l'imagerie est utilisée pour classifier les espaces verts. Les auteurs n'ont présenté aucun résultat quant à leur classification.

## **Conclusion**

La combinaison de l'imagerie optique HR et du RADAR est une combinaison intéressante. Il serait pertinent de tester la méthode de Hong et al. (2015) sur des images satellitaires HR. En ce qui concerne l'utilisation de l'imagerie combinée aux données LiDAR, la méthode de Wu et al. (2013) est limitée à l'eau sans turbidité et sans pollution. Cette limitation ne permet pas d'appliquer cette méthode à l'échelle nationale. La méthode de Zhan et al. (2002) n'a pas cette limitation. Le tableau 3.3 fait la synthèse des méthodes d'extraction de l'hydrographie utilisant l'imagerie combinée à un autre capteur.

Tableau 3.3 - Synthèse des méthodes d'extraction de l'hydrographie utilisant l'imagerie optique combinée à un autre capteur.

Méthode	Avantages et limites	Automatisation	Maturité	UA*	PA**	Qualité*** Kappa****
Hong <i>et al.</i> (2015)	- Application aux images HR à tester	- Faible - Différents seuils	- Faible - Chaîne complexe	Entre 49 % et 60 %	Entre 82 % et 83 %	Entre 84 % et 89 %  Inconnu
Wu <i>et al.</i> (2013)	- Image RVB suffisante - Turbidité ou qualité de l'eau limite l'application de cette méthode	- Faible - Difficilement applicable d'une scène à l'autre	- Faible - Nécessite de l'eau calme, sans turbidité	99 %	Entre 92 % et 94 %	Entre 96 % et 97 %  Inconnu
Zhan <i>et al.</i> (2002)	- Permet la classification des bâtiments, de la végétation et de l'eau - Multispectrale	- Bonne - Peu de paramètres	- Bonne - Chaîne de traitements simple	Inconnu	Inconnu	Inconnu

\* La précision de l'utilisateur (UA) se définit comme suit :  $100 * \frac{TP}{TP+FP}$

\*\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\*\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

### 3.3 Applications opérationnelles

Le Centre de recherche informatique de Montréal (CRIM) a réalisé beaucoup de recherches et quelques applications sur l'extraction de l'hydrographie à partir d'imagerie satellitaire. Ils ont développé un algorithme permettant d'extraire l'hydrographie surfacique à partir d'images Spot et Landsat 8. Les plans d'eau, qui proviennent originalement du site de RNCAN, sont mis à jour à partir de l'extraction. Deux applications ont été dérivées de cet algorithme. La première application est AutoCarto<sup>2</sup>. Cette application développée pour RNCAN permet d'extraire les plans d'eau à partir d'images SPOT, de comparer le résultat de cette extraction avec les plans d'eau contenus dans la base de données géospatiales (BDG) et de guider l'opérateur dans la mise à jour en indiquant les zones où il y a des modifications majeures ou des ajouts de plans d'eau (CRIM, 2017). L'application utilise un algorithme de contours actifs à partir des données présentes dans la BDG pour établir les différences et guider la mise à jour. La deuxième application développée par le CRIM, CanGeo<sup>3</sup>, est un service web permettant d'accéder aux mises à jour des données hydrographiques initialement disponibles sur le site web de Géobase (CRIM, n.d.). Les mises à jour ont été produites en utilisant des images Landsat 8.

La recherche effectuée n'a pas permis de trouver d'article utilisant un ConvNet pour extraire l'hydrographie. Néanmoins, un étudiant de l'Université d'Edinburgh a développé et mis à disposition en licence libre un ConvNet permettant d'extraire les plans d'eau à partir d'images satellitaires (Reichelt, 2017). Le réseau, nommé WaterNet<sup>4</sup>, a été développé pour être utilisé en *Python* et permet l'utilisation des données vectorielles *Open Street Map* (OSM) pour entraîner le réseau.

---

<sup>2</sup> Liens vers un démo web de l'application AutoCarto : <http://geo-ti.crim.ca/>

<sup>3</sup> Site web du projet CanGeo : <http://cangeo.crim.ca/hydro>

<sup>4</sup> Site web de téléchargement du WaterNet : <https://github.com/treigerm/WaterNet>

## 4 Extraction des routes

### 4.1 Méthodes utilisant l'imagerie optique

L'extraction des routes à partir d'imagerie satellitaire optique HR est largement étudiée et énormément d'articles ont été rédigés sur ce sujet. La présente section recense les études les plus récentes et ayant un grand potentiel d'utilisation. Par ailleurs, l'état de l'art présenté dans l'article de Das *et al.* (2011) est très pertinent concernant les méthodes développées avant 2010. Bien qu'il en existe plusieurs autres, cet article peut agir en excellent complément à la présente revue. Le tableau 4.2 présente une synthèse des méthodes présentées dans la présente section.

#### Méthode basée sur les caractéristiques de forme

Maboudi *et al.* (2016) propose une méthode intéressante d'extraction des routes à partir d'imagerie HR. La segmentation des objets de l'image est réalisée avec une approche multirésolution. Pour distinguer et classifier les objets de routes des autres objets, ils ont identifié quatre caractéristiques appartenant aux routes, soit : les routes sont des structures allongées d'une largeur délimitée, les segments routiers sont assez longs, la surface des routes est généralement homogène localement et les courbes des routes ne changent pas drastiquement. Ces caractéristiques ont été modélisées et permettent de bien distinguer les objets de routes du reste. Finalement, pour combler les manques dans la détection des routes et compléter le réseau, un *tensor voting* a été appliqué, préalablement à un algorithme d'amincissement pour extraire la ligne de centre des routes. L'article inclut une comparaison des résultats obtenus avec quelques-unes des autres méthodes présentées dans cette section. Le tableau 4.1 présente un extrait des résultats observés pour chacune de celles-ci. Le principe du *tensor voting* est détaillé à l'annexe I.

Tableau 4.1 - Comparaison des résultats de l'extraction des routes (Maboudi *et al.*, 2016).

Zone test	Méthode	UA (%)	PA (%)	Qualité (%)
1	Wang <i>et al.</i> , 2015	70,0	75,0	74,0
	Maboudi <i>et al.</i> , 2016	93,4	89,9	84,8
2	Ameri <i>et al.</i> , 2015	94,0	89,0	84,0
	Maboudi <i>et al.</i> , 2016	95,9	93,4	89,8

Parmi les méthodes utilisées pour la comparaison, celle de Wang *et al.* (2015) et Ameri *et al.* (2015) sont décrites dans la présente section.

### **Méthode utilisant un réseau de neurones artificiels (ANN)**

Mokhtarzade *et al.* (2007) utilisent l'ANN pour extraire les routes des images HR. Les auteurs ont utilisé des portions d'images IKONOS et QuickBird dans le cadre de leur étude. Un réseau de neurones artificiels efficace nécessite un bon paramétrage en amont. Parmi les paramètres nécessaires, on retrouve la taille du réseau ainsi que les paramètres de départ de l'algorithme. Dans ce cas-ci, les paramètres de départ sont l'information spectrale et l'information de voisinage et de texture des routes. Dans leur étude, Mokhtarzade *et al.* (2007) ont étudiés l'effet sur les résultats de la taille du réseau de neurones ainsi que de certains paramètres comme l'information sur les bordures et la texture des routes. Il a pu établir une taille maximale de réseau ainsi que découvrir quel est le paramètre de départ ayant le plus d'effet sur le résultat.

### **Méthode utilisant un ConvNet et un automate à états fini**

Wang *et al.* (2015) ont utilisé les réseaux convolutifs pour effectuer l'extraction des routes. Leur approche considère que les routes forment un réseau connecté, formant du même coup un seul et unique objet dans l'image. Le ConvNet est utilisé pour détecter les formes et alignements des routes (ligne droite, virage à gauche, virage à droite, intersection et passage bloqué). La recherche de routes est ainsi dirigée à l'aide d'un automate à états fini et en fonction de l'alignement. L'entraînement de l'algorithme a été fait en combinant l'imagerie HR (QuickBird) et des vecteurs de réseau routier sur une zone de Chine. Un échantillon de 500 000 paires d'imageries-vecteurs a été utilisé pour entraîner l'algorithme. Les tests ont été effectués sur plusieurs images de plusieurs régions en Chine.

### **Méthode utilisant deux ConvNet en cascade**

Les réseaux convolutifs ont aussi été utilisés dans une recherche de Cheng *et al.* (2017). Leur méthode permet d'extraire les routes sous forme polygonale ainsi que la ligne de centre de ces routes. Les auteurs utilisent deux réseaux convolutifs en cascade pour extraire leur information. Le premier ConvNet sert à détecter les pixels de

routes alors que le deuxième permet d'extraire la ligne de centre des routes. Pour que cette méthode fonctionne, les deux réseaux doivent être entraînés. Ils ont utilisé 180 images d'une taille minimale de 300 X 300 pixels et de 1,2 m de résolution pour faire cet entraînement. Finalement, ils ont comparé les résultats de l'extraction réalisée sur 30 images de test avec cinq autres méthodes (Huang et Zhang 2009 ; Shi *et al.*, 2014 ; Cheng *et al.*, 2016 ; Long *et al.*, 2015 ; Navab *et al.*, 2015). Les méthodes de Huang et Zhang (2009) et de Shi *et al.* (2014) sont également présentées dans cette section. La comparaison a démontré que l'algorithme de Cheng *et al.* (2017) a surpassé les autres méthodes autant au niveau de la détection des pixels de routes que pour l'extraction des lignes de centre. La qualité moyenne des résultats est particulièrement supérieure pour l'extraction des lignes de centre de route.

### **Méthodes utilisant l'intelligence distribuée**

Maboudi *et al.* (2017) proposent une méthode qui utilise une segmentation basée sur la région : la segmentation multirésolution. L'intérêt de son étude réside dans l'utilisation de l'intelligence distribuée, plus précisément de la méthode *Ant Colony Optimisation* (ACO) pour classifier le résultat de la segmentation. Comme son nom l'indique, ACO est basée sur le comportement des fourmis. Le principe est que l'algorithme dépose des fourmis sur l'image et que chacune de ces fourmis explore son environnement à la recherche de connexions intéressantes. L'algorithme évalue la qualité d'une connexion par rapport à des caractéristiques spectrales, structurales et topologiques préalablement déterminées par l'utilisateur. L'information sur le chemin parcouru jusqu'à la connexion ainsi que la qualité de cette connexion est ensuite communiquée aux autres fourmis et sert de poids dans le calcul des prochains chemins. Une connexion forte et un chemin court vont influencer le chemin emprunté par les prochaines fourmis. Les itérations subséquentes permettent de raffiner la détection des routes. La segmentation multirésolution ainsi que l'intelligence distribuée sont expliqués à l'annexe I.

Ameri *et al.* (2015) proposent une approche semblable à celle de Maboudi *et al.* (2017). Ils ont utilisé une classification floue pour segmenter et classifier les régions de routes et ont utilisé un algorithme d'intelligence distribuée de type *Particle Swarm Optimization* (PSO) pour vectoriser le réseau routier.

## **Méthodes utilisant un support vecteur machine**

Huang et Zhang (2009) ont extraits la ligne de centre des routes avec une méthode qui combine la segmentation multiéchelle utilisant la structure et l'information spectrale des objets avec un SVM pour en faire la classification. Le SVM est appliqué sur la segmentation à chacune des échelles et la détection de la ligne de centre se fait avec un algorithme d'amincissement appliqué sur la fusion des classifications multiéchelles. En complément, cette méthode a été testée dans l'étude de Cheng *et al.* (2017).

La méthode proposée par Shi *et al.* (2014) utilise une classification pixel par pixel à partir de l'information spectrale et spatiale de l'image. Pour y parvenir, ils ont appliqué un *General Adaptive Neighborhood* (GAN) suivi d'une classification SVM. Comme son nom l'indique, l'approche de traitement GAN permet d'adapter la notion de voisinage. La position relative des voisins est modifiée en fonction des caractéristiques spectrales, texturales ou spatiales recherchées. Dans ce cas-ci, le but de cette classification est de différencier les pixels de routes du reste. Une deuxième classification SVM est appliquée sur l'image de base pour prendre en compte les propriétés des routes afin d'améliorer la distinction entre les faux positifs (stationnements, sols nus, bâtiments) et les routes. Le résultat des deux classifications est ensuite fusionné. Un filtre sur la forme des éléments permet ensuite de retirer les éléments classifiés comme étant des routes, mais qui n'ont pas les caractéristiques linéaires de ces dernières. Pour déterminer la position de la ligne de centre des routes, un algorithme d'amincissement est appliqué. L'étude a utilisé des images provenant du capteur Ziyuan-3 ayant une résolution de six mètres. Avec une telle résolution, seulement les routes majeures ont été extraites. Cette méthode a aussi été testée dans l'étude de Cheng *et al.* (2017).

## **Méthode permettant de qualifier la qualité de la route**

Il est généralement très difficile d'obtenir de l'information attributive sur l'objet extrait lorsque l'on utilise simplement l'imagerie optique. Shahi *et al.* (2016) ont étudié la possibilité de qualifier la condition de l'asphalte des routes. Leur méthode a été testée sur des images WorldView-2. Ils ont utilisé un algorithme de classification basé sur le Chi carré qui leur permet de qualifier de bonne ou mauvaise la condition de la route. Cette approche

est intéressante pour ajouter de l'information aux routes extraites. Les résultats de leur étude ont montré une précision de 83 % avec un coefficient kappa de 0,68. Le Chi carré est présenté à l'annexe I.

## **Conclusion**

Les articles portant sur l'extraction du réseau routier par images optiques HR sont très récents. Les méthodes utilisant les algorithmes d'apprentissage automatique sont très populaires pour ce type d'extraction. Les grandes étapes d'extraction du réseau routier à partir d'images HR sont assez semblables d'une méthode à l'autre. Il s'agit de classifier l'image pour trouver les routes, de relier les polygones issus de la classification entre eux pour créer un élément routier et d'appliquer un algorithme d'amincissement pour obtenir la ligne de centre du pavage sur les routes. De plus, la plupart des auteurs ont réussi à obtenir des résultats d'extraction supérieurs à 90 %, démontrant un potentiel très intéressant. La méthode de Cheng *et al.* (2017), utilisant deux ConvNet en cascade, semble très efficace, robuste et adaptée à plusieurs sites. De plus, elle a été comparée avec plusieurs autres méthodes. La mise en place de cette méthode demande davantage de ressources (données d'entraînements), mais en vaut la peine dans un contexte d'extraction à l'échelle nationale. Cette méthode d'évaluation ainsi que la synthèse des méthodes de cette section se retrouvent dans le tableau 4.2.

Tableau 4.2 - Synthèse des méthodes d'extraction des routes utilisant l'imagerie optique.

Méthode	Avantages et limites	Automatisation	Maturité	UA*	PA**	Qualité*** kappa****
Maboudi <i>et al.</i> (2016)	<ul style="list-style-type: none"> <li>- Image RVB suffisante</li> <li>- Résultats très intéressants</li> <li>- <i>Tensor voting</i> complexe à implanter</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Facilement transposable d'une scène à l'autre</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Mise en place du <i>tensor voting</i> complexe</li> </ul>	Entre 93 % et 99 %	Entre 90 % et 97 %	Entre 85 % et 96 %  Inconnu
Mokhtarzade <i>et al.</i> (2007)	<ul style="list-style-type: none"> <li>- Image RVB suffisante</li> <li>- Résultats basés sur de très petites zones</li> <li>- ANN de petite dimension</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Nécessite une quantité importante de données d'entraînement</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Mise en place du ANN</li> </ul>	Inconnu	Inconnu	Entre 92 % et 95 %  Entre 0,61 et 0,72
Wang <i>et al.</i> (2015)	<ul style="list-style-type: none"> <li>- Image RVB suffisante</li> <li>- Résultats intéressants</li> <li>- Entraînement du ConvNet</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Nécessite une quantité importante de données d'entraînement</li> <li>- Interaction nécessaire (initialisation des points de routes)</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Processus complexe</li> <li>- Mise en place du ConvNet</li> </ul>	70 %	75 %	74 %  Inconnu
Cheng <i>et al.</i> (2017)	<ul style="list-style-type: none"> <li>- Image RVB suffisante</li> <li>- Meilleurs résultats</li> <li>- Données d'entraînement disponibles</li> <li>- Entraînement complexe (2 ConvNet)</li> </ul>	<ul style="list-style-type: none"> <li>- Excellente</li> <li>- Aucune interaction nécessaire</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Processus complexe</li> <li>- Mise en place des ConvNet</li> </ul>	Environ 95 %	Environ 96 %	Environ 92 %  Inconnu
Maboudi <i>et al.</i> (2017)	<ul style="list-style-type: none"> <li>- Multispectrale</li> <li>- Manque d'information sur le ACO</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Interactions nécessaires</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Processus complexe</li> <li>- Mise en place du ACO</li> </ul>	89 %	87 %	78 %  Inconnu
Ameri <i>et al.</i> (2015)	<ul style="list-style-type: none"> <li>- Détection des routes peu détaillée</li> <li>- Multispectrale</li> </ul>	<ul style="list-style-type: none"> <li>- Bonne</li> <li>- Regroupement semi-automatique en <i>clusters</i> de routes</li> <li>- Vectorisation automatique de la ligne</li> </ul>	<ul style="list-style-type: none"> <li>- Faible</li> <li>- Processus complexe</li> <li>- Manque de détail sur la méthode</li> </ul>	90 %	91%	83 %  Inconnu

		de centre				
Huang et Zhang (2009)	- Processus qui assure la continuité du réseau - Multispectrale	- Faible - Beaucoup d'interactions	- Excellente - Processus simple - Outils en place dans les logiciels courants	Entre 90 % et 93 %	Entre 78 % et 81 %	Inconnu
Shi <i>et al.</i> (2014)	- Multispectrale - Résultats très variables en fonction du capteur et de la zone d'étude	- Faible - Beaucoup d'interactions	- Bonne - Outils en place dans les logiciels courants	Entre 62 % et 98 %	Entre 34 % et 94 %	Entre 29 % et 92 %  Inconnu

\* La précision de l'utilisateur (UA) se définit comme suit :  $100 * \frac{TP}{TP+FP}$

\*\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\*\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

## 4.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur

Peu d'études ont été recensées concernant l'utilisation de l'imagerie satellitaire optique combinée au RADAR ou au LiDAR. Les résultats sont présentés dans le tableau 4.3, en fin de section.

### Méthode combinée au RADAR

Fard *et al.* (2014) ont développé une méthode de classification en milieu urbain combinant le RADAR à synthèse d'ouverture (RSO) et l'imagerie optique HR. L'image RADAR utilisée provient du capteur ALOS/PALSAR alors que l'image optique provient d'IKONOS. Chacune des images est individuellement classifiée et c'est le résultat des classifications qui est fusionné. Une classification texturale en trois classes (ville, terre en friche et route) est utilisée sur l'image optique. Ils ont utilisé l'opérateur de produit pour fusionner les classifications et ont indiqué que la fusion a augmenté le résultat de 4 %-8 %.

### Méthode combinée au LiDAR

Liu et Lim (2016) ont présenté une méthode d'extraction du réseau routier qui combine les données LiDAR et l'imagerie HR. Leur processus peut être divisé en cinq étapes. Dans un premier temps, l'image et le LiDAR sont fusionnés. Pour ce faire, ils ont assigné la valeur RVB du pixel correspondant dans l'image à chacun des points du nuage de points LiDAR. Dans un deuxième temps, ils ont divisé le nuage de points en plusieurs fichiers afin de réduire le nombre de points à traiter simultanément. La classification du nuage de points se fait ensuite en utilisant une suite de règles permettant de discriminer les routes potentielles du reste. Ces règles utilisent l'élévation, l'intensité et la valeur RVB des points et de leurs voisins. Quatrièmement, les auteurs ont utilisé une classification par voisins les plus proches (*knn*) pour distinguer les routes des aires de stationnement, en utilisant la forme allongée des routes comme élément discriminant. Finalement, ils ont appliqué une interpolation selon l'inverse de la distance pondérée (*IDW*) pour enlever les trous causés par la présence d'arbres couvrant la route et compléter l'extraction. La ligne de centre a été déterminée en utilisant un algorithme d'ajustement de courbe.

## **Conclusion**

Les méthodes d'extraction des routes à partir d'imagerie combinée à un autre capteur ne sont pas nombreuses. La méthode de Fard *et al.* (2014) utilisant le RADAR est assez simple à mettre en place et ils ont démontré que la combinaison des deux types de données améliore la qualité de la classification. Par contre, leur méthode présente seulement la classification, sans appliquer d'algorithme pour créer le réseau routier. Liu et Lim (2016), quant à eux présentent une méthode permettant aussi d'extraire le réseau routier. Les résultats et la synthèse des deux méthodes sont présentés dans le tableau 4.3.

Tableau 4.3 - Synthèse des méthodes d'extraction des routes utilisant l'imagerie optique combinée à un autre capteur.

Méthode	Avantages et limites	Automatisation	Maturité	UA*	PA**	Qualité*** Kappa****
Fard <i>et al.</i> (2014)	- Excellents résultats - Multispectrale	- Bonne - Peu d'interactions avec l'utilisateur	- Bonne - Méthode assez simple	Inconnu	Inconnu	98 %  0,96
Liu et Lim (2016)	- Image RVB suffisante - Résultats à améliorer	- Excellente - 100 % automatisable	- Bonne - Processus simple	Entre 88 % et 91 %	Entre 80 % et 89 %	Entre 79 % et 88 %  Inconnu

\* La précision de l'utilisateur (UA) se définit comme suit :  $100 * \frac{TP}{TP+FP}$

\*\* La précision du producteur (PA) se définit comme suit :  $100 * \frac{TP}{TP+FN}$

\*\*\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\*\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

### 4.3 Applications opérationnelles

Il y a quelques années, le laboratoire de télédétection de l'Université de Montréal a été mandaté pour développer « une application dédiée à la détection automatique et la mise à jour du réseau routier des cartes topographiques à l'échelle 1 : 20 000 » (Bélanger, 2011). L'approche utilisée est détaillée dans le mémoire de maîtrise de Bélanger (2011). De manière générale, l'approche vise à modifier le progiciel Sigma<sup>0</sup> pour extraire les routes, comparer l'extraction avec les segments de la Base de données topographiques du Québec (BDTQ), évaluer les changements et qualifier les segments comme étant intacts, modifiés ou disparus. L'application résultante nommée SIGMA-ROUTES a réussi à détecter 78 % des routes existantes sur le site d'étude. Néanmoins, l'application n'est pas en mesure d'extraire les routes qui ont été ajoutées. Le logiciel utilise la bande panchromatique des images SPOT-5 et la zone testée dans Bélanger (2011) est une partie de la ville de Sherbrooke. Il n'est pas possible d'utiliser le logiciel développé puisqu'il a été développé pour le compte du gouvernement provincial.

Johnson (2016) a développé une application appelée DeepOSM<sup>5</sup> qui permet de télécharger des données de routes d'OSM et prépare des données d'évaluation et d'entraînement qui sont utilisées dans un ConvNet. Le résultat du ConvNet est une image avec des prédictions sur les discordances entre les données OSM et l'image en entrée. Cette application est en utilisation libre et gratuite.

---

<sup>5</sup> Lien vers l'application : <https://github.com/trailbehind/DeepOSM>

## 5 Extraction de la végétation urbaine

### 5.1 Méthodes utilisant l'imagerie optique

La présente section recense les méthodes d'extraction de végétation en contexte urbain, à partir d'imagerie satellitaire optique HR. Les résultats ainsi qu'une synthèse des méthodes se retrouvent au tableau 5.1.

#### Indice de végétation utilisant le proche infra rouge

L'extraction de la végétation à partir d'images multispectrales est depuis longtemps étudiée. En effet, dès 1974, Rouse *et al.* ont introduit le NDVI. Cet indice est la différence normalisée entre la forte réflectance de la végétation dans le proche infrarouge et la faible réflectance dans le rouge. Encore aujourd'hui, le NDVI est largement utilisé et permet facilement de discriminer la végétation du reste (Greenhill *et al.*, 2003 ; Tunay *et al.*, 2007 ; Van Delm et Gulinck, 2011 ; Zhang et Feng, 2010). La limite à l'utilisation de cet indice est la nécessité de la bande spectrale proche infrarouge. La formule 5.1 décrit le calcul du NDVI :

$$NDVI = \frac{NIR - Rouge}{NIR + Rouge}$$

Équation 5.1 - NDVI (Rouse *et al.*, 1974).

#### Indices de végétation utilisant les bandes visibles

D'autres indices ont été développés pour utiliser les bandes visibles uniquement. Le premier, le *Normalized Green Red Difference Index* (NGRDI) développé par Tucker (1979) est la différence normalisée du vert et du rouge. Plusieurs auteurs ont montré que le NDVI est meilleur que le NGRDI pour le suivi de la végétation (Campbell et Wynne, 2011 ; Tucker, 1979). Par contre, Motohka *et al.* (2010) ont montré que cet indice donne d'aussi bons résultats que le NDVI.

Le deuxième indice utilisant les bandes visibles est le *green leaf index* (GLI). Gobron *et al.* (2000) ont développé cet indice dont la formule est la suivante :

$$GLI = \frac{2 * Vert - Rouge - Bleu}{2 * vert + Rouge + Bleu}$$

Équation 5.2 - *Green leaf index* (Gobron *et al.*, 2000).

Il est montré que le GLI donne des résultats très similaires au NDVI (Gobron *et al.*, 2000 ; Hunt *et al.*, 2011). Finalement, le *triangular greenness index* (TGI) a été développé par Hunt *et al.* (2011). Les auteurs indiquent que cet indice est fortement influencé par la teneur en chlorophylle et que d'autres études utilisant cet indice doivent être menées avant de l'utiliser aussi largement que le NDVI.

### **Méthode orientée-objet de classification de la couverture du sol**

L'extraction de la végétation est souvent une composante de la classification de la couverture du sol. En ce sens, Myint *et al.* (2011) ont développé une méthode de classification de la couverture du sol par une approche orientée-objet. Ils ont comparé leur méthode à une approche pixel par pixel. Leur méthode utilise un algorithme de segmentation multirésolution. Pour la classification, ils ont employé un algorithme de plus proche voisin. Les auteurs ont indiqué avoir utilisé quatre ou cinq objets d'entraînement pour classer les arbres et le gazon. Les résultats montrent une précision globale de 95 % avec un coefficient kappa de 0,94 pour la classification des sept classes (bâtiment, sol nu, gazon, matériel imperméable, piscine, arbre et lac).

### **Méthode de classification de l'utilisation du sol utilisant un réseau de Bayes**

Li *et al.* (2016) ont développé une méthode de classification de l'utilisation du sol basée sur un réseau de Bayes. Les auteurs ont classifié la couverture du sol en onze classes utilisant une approche orientée-objet. Les classes identifiées sont : gazon, arbre, ombre, eau, sol nu, toit sombre, toit gris, toit couleur brique, toit bleu, toit clair et autres. La segmentation multirésolution en objet a été réalisée avec un algorithme implanté dans le logiciel eCognition où les paramètres ont été déterminés par essais et erreurs. Les auteurs ont mentionné avoir délibérément sursegmenté l'image afin d'améliorer les résultats de la classification. Un SVM a par la suite été entraîné et utilisé pour classer les objets segmentés. La précision globale de la classification sur une image Pléiade est de 90 % avec un coefficient kappa de 0,89. Les arbres ont été bien classifiés à 100 % et le gazon à

98 %. Le processus de Li *et al.* (2016) permet par la suite de qualifier la densité et la complexité des bâtiments et ultimement utiliser le réseau de Bayes pour extraire l'utilisation du sol.

### **Méthodes utilisant l'apprentissage profond**

Scott *et al.* (2017) ont testé trois réseaux de neurones convolutifs pour produire la classification de la couverture du sol. Les trois réseaux testés sont : CaffeNet (Jia *et al.*, 2014), GoogLeNet (Szegedy *et al.*, 2015) et ResNet (He *et al.*, 2016). Les auteurs ont utilisé des algorithmes préalablement entraînés pour une tâche et les ont appliqués à l'extraction à partir d'imagerie satellitaire. Cette méthode appelée « *transfert learning* » permet de réduire le temps d'entraînement. Pour augmenter le volume de données d'entraînement, ils ont appliqué plusieurs transformations de rotation et de transposition sur les données d'entraînement qu'ils avaient à leur disposition. Cette technique est appelée « *data augmentation* ». Cela a permis d'augmenter 120 fois le nombre de données d'entraînement. Les résultats de classification obtenus avec les trois algorithmes sont semblables (autour de 98 %). Les auteurs ont déposé leur code sur Github<sup>6</sup>.

Les réseaux de neurones convolutifs ont été utilisés par Dahmane *et al.* (2016) dans le but d'extraire les voitures et les arbres individuels à partir d'images Pléiades. Tout comme Scott *et al.* (2017) les auteurs ont utilisé un algorithme convolutifs préentraîné, soit le CaffeNet. Les auteurs ont utilisé 6 307 zones de 1024 m<sup>2</sup> d'une scène à Vancouver pour entraîner le réseau CaffeNet. Ils ont ensuite testé leur algorithme sur une scène de la Ville de Québec. Leur méthodologie est très peu détaillée, mais ils ont mentionné avoir obtenu de meilleurs résultats en combinant les bandes R, V et PIR. La probabilité de bonne détection des arbres individuels est supérieure à 0,99.

### **Méthode de classification des types de végétation utilisant un arbre décisionnel**

Zhang *et al.*, 2010 ont développé une méthode orientée-objet pour classifier les types de végétation selon cinq classes soit : végétation aquatique, feuillue, conifère, gazon artificiel et gazon. Leur méthode se compose de quatre étapes. La première consiste à supprimer les zones d'ombres par une méthode hiérarchique basée sur

---

<sup>6</sup> [https://github.com/scottgs/ML\\_DataAugmentation](https://github.com/scottgs/ML_DataAugmentation)

l'information spectrale et texturale. Les détails de cette étape ne sont pas précisés dans l'article. Par la suite, deux méthodes de segmentation sont appliquées une après l'autre. Dans un premier temps, ils ont appliqué le NDVI pour obtenir la végétation par pixel. La deuxième segmentation utilise la méthode de croissance par région afin d'obtenir les objets représentant la végétation. Ensuite, pour chacune des zones de végétation segmentées, ils ont calculé un ensemble de caractéristiques spectrales, texturales et de formes avant de procéder à une analyse par composante principale afin de réduire les dimensions des objets tout en gardant l'information pertinente. Finalement, les auteurs ont utilisé un arbre décisionnel (CART) pour classifier la végétation en cinq classes. La précision globale de leur classification est de 89 %, avec un coefficient kappa de 0,85.

## **Conclusion**

Le NDVI est l'indice le plus utilisé pour détecter la végétation dans une image multispectrale. Il s'agit d'un indice fiable, simple et efficace. Le recours aux indices utilisant les bandes visibles est moins commun. Dans chacun des cas, les seuils à utiliser varient d'une scène à l'autre. Les méthodes de classification de la couverture du sol réussissent bien à classifier la végétation, en plus de permettre l'extraction d'autres types d'information. Par contre, ces méthodes sont plus difficiles à automatiser. Les méthodes utilisant l'apprentissage profond donnent des résultats quasi parfaits de classification de la végétation et ne requièrent souvent pas d'images multispectrales. À cet effet, l'approche de Dahmane *et al.* (2016) devrait être étudié davantage. Finalement, la méthode de classification des types de végétation par Zhang *et al.* (2010) est une solution intéressante pour associer des attributs à la végétation extraite. Le tableau 5.1 fait la synthèse des méthodes et des résultats.

Tableau 5.1 - Synthèse des méthodes d'extraction de la végétation urbaine utilisant l'imagerie optique.

Méthode	Avantages et limites	Automatisation	Maturité	Qualité* Kappa**
Rouse <i>et al.</i> (1974)	- Largement utilisée - Multispectrale	- Excellente - Rapport de bandes spectrales	- Excellente - Très simple à implémenter	Résultats variables en fonction du seuil utilisé
Tucker (1979)	- Image RVB suffisante	- Excellente - Rapport de bandes spectrales	- Excellente - Très simple à implémenter	Résultats variables en fonction du seuil utilisé
Gobron <i>et al.</i> (2000)	- Image RVB suffisante	- Excellente - Rapport de bandes spectrales	- Excellente - Très simple à implémenter	Résultats variables en fonction du seuil utilisé
Hunt <i>et al.</i> (2011)	- Image RVB suffisante - Performances de l'indice à prouver	- Excellente - Rapport de bandes spectrales	- Excellente - Très simple à implémenter	Résultats variables en fonction du seuil utilisé
Myint <i>et al.</i> (2011)	- Permet de classifier plusieurs types d'informations - Excellents résultats - Multispectrale	- Faible - Classification supervisée	- Bonne - Simple à implémenter	95 %  0,94
Li <i>et al.</i> (2016)	- Permet de classifier plusieurs types d'informations - Excellents résultats - Multispectrale - Manque de détail sur la méthode	- Faible - Difficilement applicable d'une scène à l'autre	- Bonne - Simple à implémenter	83 %  0,80
Scott <i>et al.</i> (2017)	- Utilise un réseau préalablement entraîné - Excellents résultats - Permet de classifier n'importe quoi, selon les données d'entraînement - Quantité importante de données pour entraînement	- Bonne - Variable en fonction des données d'entraînement	- Excellente - Un peu de développement pour adapter le réseau	Entre 98% et 99 %  Inconnu
Dahmane <i>et al.</i> (2016)	- Utilise un réseau préalablement entraîné - Excellents résultats - Permet de détecter les arbres individuels - Quantité importante de données pour entraînement	- Bonne - Variable en fonction des données d'entraînement	- Excellente - Un peu de développement pour adapter le réseau	Autour de 99 %  Inconnu
Zhang <i>et al.</i>	- Permet de discriminer les types de	- Bonne	- Bonne	89 %

(2010)	végétation - Multispectrale	- Peu de paramètres - Applicable sur différentes scènes	- Processus simple - Manque de détails sur la suppression de l'ombre	0,85
--------	--------------------------------	--	---	------

\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

## 5.2 Méthodes utilisant l'imagerie optique combinée à un autre capteur

La présente revue n'a pas été en mesure de trouver de méthodes d'extraction d'informations cartographiques utilisant l'imagerie satellitaire combinée au RADAR. Les méthodes suivantes utilisent une combinaison de l'imagerie satellitaire au LiDAR. Les résultats et une synthèse des méthodes sont présentés au tableau 5.2.

### **Méthode de classification *pseudo-waveform* à partir des données LiDAR**

En 2015, Zhou et Qiu ont développé une méthode qui combine l'utilisation d'images multispectrales WorldView-2 et les données LiDAR pour classifier les bâtiments, le gazon, le pavé, l'ombrage et les arbres. La segmentation de l'image est effectuée à partir du logiciel ENVI Zoom. Ensuite, les auteurs ont appliqué une première classification orientée-objet sur l'image segmentée et utilisant les histogrammes spectraux des cinq classes à extraire. En parallèle, ils ont procédé à une autre classification avec l'image segmentée et les données LiDAR. Le principe est que pour chaque zone segmentée de l'image, ils ont extrait les points LiDAR situés à l'intérieur et ont calculé l'histogramme de ces points en fonction de la hauteur afin de détecter les différences de hauteurs et ainsi raffiner la segmentation. Cette classification est appelée *pseudo-waveform*. Le résultat des deux classifications a finalement été fusionné. Les résultats de la classification finale pour cette méthode sont de 97 % avec un coefficient kappa de 0,97.

### **Classification des types de végétation par apprentissage actif**

Rougier *et al.* (2016) ont comparé la performance de trois algorithmes d'apprentissage actif pour classifier la végétation urbaine en deux classes soit : arbres et herbacés. Leur méthode utilise des images Pléiades ainsi qu'un MNS normalisé. La segmentation des images a été effectuée en combinant une approche multirésolution et une approche basée sur la différence spectrale. Ensuite, pour chacune des régions, ils ont calculé une foule d'informations spectrales, texturales et géométriques (moyenne des bandes, écart type des valeurs de pixels, minimum, maximum, matrice de cooccurrence, aire, asymétrie, etc.). Par la suite, ils ont réalisé l'entraînement initial de l'algorithme d'apprentissage actif par échantillonnage aléatoire stratifié. Finalement, ils ont comparé trois stratégies d'apprentissage actif afin d'en évaluer la performance. Les résultats montrent que les trois

stratégies ont obtenu des résultats similaires. De plus, les arbres ont été beaucoup mieux classifiés que les herbacés à environ 80 % comparativement à 50 %. L'apprentissage actif est présenté à l'annexe I.

## **Conclusion**

Pour extraire les bâtiments et la végétation, la méthode de Zhou et Qiu (2015) semble très intéressante. Le potentiel d'automatisation est très bon et le processus est simple à mettre en place. Les résultats montrent que l'algorithme profite de l'avantage spectral du capteur optique et de l'avantage tridimensionnel des données LiDAR pour bien classifier l'information. L'approche de Rougier *et al.* (2016) peut être utilisée pour classifier les types de végétation, mais elle demande davantage de développement. Le tableau 5.2 fait la synthèse des deux méthodes présentées dans cette section.

Tableau 5.2 - Synthèse des méthodes d'extraction de la végétation urbaine utilisant l'imagerie optique combinée à un autre capteur.

Méthode	Avantages et limites	Automatisation	Maturité	Qualité* Kappa**
Zhou et Qiu (2015)	- Permet de classifier plusieurs types d'informations - Multispectrale	- Excellente	- Bonne - Simple à mettre en place	97 % 0,97
Rougier <i>et al.</i> (2016)	- Permet de discriminer les types de végétation - Multispectrale - Résultats moyens (50 % pour les herbacés)	- Faible - Beaucoup de paramètres	- Bonne - Processus avec beaucoup d'étapes, mais assez simple	Inconnu

\* La qualité se définit comme suit :  $100 * \frac{TP}{TP+FP+FN}$

\*\* La définition de kappa se trouve dans le compendium des méthodes.

Où :

FN = Faux négatifs, FP = Faux positifs et TP = Vrais positifs

### 5.3 Applications opérationnelles

Pham *et al.*, 2011 ont proposé une application d'extraction de la végétation en milieu urbain. Leur but est de cartographier le couvert végétal de Montréal afin d'en étudier la relation avec la situation démographique des quartiers. Le couvert végétal est extrait à partir de deux images QuickBird acquises en 2007. Les auteurs ont indiqué avoir fait la segmentation en première étape sans spécifier quel algorithme ils ont utilisé. La classification des types de végétation est faite en appliquant le *modified soil adjusted vegetation index* (MSAVI) à deux échelles différentes sur les objets préalablement segmentés. La précision globale de la classification des deux classes (arbres et gazon) est de 73 % avec un coefficient kappa de 0,50. Les auteurs ont par la suite étudié la relation entre le couvert végétal et la situation démographique des quartiers de Montréal. Les auteurs ont indiqué avoir utilisé le logiciel eCognition 8.1 pour effectuer la classification.

## 6 Conclusion sur les méthodes d'extraction

L'extraction d'informations cartographiques à partir d'imagerie satellitaire optique HR est largement étudiée et les méthodes pour ce faire sont nombreuses et en constante évolution. L'état actuel des méthodes d'extraction montre que les stratégies de classification pixel par pixel et orientée-objet sont, encore aujourd'hui, largement utilisées. Parmi ces stratégies, la méthode montrant le plus de potentiel pour extraire les bâtiments est celle développée par Liasis et Stavrou (2016) qui utilise des images RVB et un algorithme de *snake*. Pour la thématique de l'hydrographie, les efforts de développements devraient être axés sur deux approches, soit la méthode de Wang *et al.* (2008) qui permet d'extraire les régions hydriques à partir d'images panchromatiques et la méthode de Yao *et al.* (2015) qui utilise l'information spectrale couplée à un algorithme de suppression de l'ombrage. L'approche orientée-objet optimale pour extraire les routes et le réseau routier est la méthode de Maboudi *et al.* (2016) qui utilise le *Tensor Voting*. Pour la thématique de la végétation, l'approche orientée-objet la plus intéressante est celle développée par Zhang *et al.* (2010) qui permet de classifier les types de végétations.

La tendance actuelle dans les méthodes d'extraction d'informations cartographiques à partir d'imagerie haute résolution est l'utilisation des algorithmes d'apprentissage automatique et d'apprentissage profond. Les capacités informatiques évoluent, les développements et avancées dans ces domaines aussi. La méthode d'apprentissage automatique développée par Yuan (2016) montre un potentiel très intéressant pour extraire la forme des bâtiments. Bien qu'aucun article n'ait été écrit pour extraire l'hydrographie en utilisant l'apprentissage automatique ou profond, l'application développée par Reichelt (2017) mérite d'être testée afin d'en évaluer les résultats. Beaucoup de méthodes utilisant l'apprentissage automatique ont été produites pour la thématique d'extraction des routes et du réseau routier. Pour cette thématique, les efforts de développements devraient être mis en place pour reproduire la méthode de Cheng *et al.* (2017) qui utilise deux ConvNet en cascade. Finalement, les efforts de développements devraient être orientés sur la méthode de Dahmane *et al.* (2016) qui utilise l'apprentissage profond pour extraire les arbres individuels.

Parmi les méthodes qui combinent l'imagerie optique avec d'autres capteurs, la méthode de Zhou et Qiu (2015) utilise le LiDAR pour améliorer la segmentation faite à partir de l'imagerie et propose une technique intéressante qui utilise les avantages de chacun des capteurs. De plus, cette méthode permet de faire l'extraction de l'eau, des bâtiments et de la végétation.

La lecture des méthodes a permis de découvrir des limitations à l'extraction. Parmi les problèmes recensés dans la littérature scientifique, on note la difficulté à discriminer certains objets ayant des caractéristiques (spectrales, spatiales et géométriques) semblables, mais dont la nature est complètement différente (Shan et Hussain, 2011). Par exemple, il est difficile de faire la distinction entre un toit et un stationnement ou entre un plan d'eau et l'ombrage causé par les édifices ayant une hauteur importante. Une autre limite à l'extraction d'informations cartographiques à partir d'imagerie optique est la difficulté à qualifier les objets extraits. Le type de bâtiment, le type de route et de revêtement sont des éléments beaucoup plus difficiles à déterminer que la forme du bâtiment ou de la route. Les attributs associés aux éléments extraits sont très limités. La cartographie collaborative pourrait être une solution adaptée à ce problème. La principale limitation à l'utilisation des algorithmes d'apprentissage automatique est la nécessité de quantités importantes de données à priori.

Les méthodes recensées dans la présente étude ont été réalisées sur des zones assez restreintes. À l'échelle nationale, les éléments à extraire sont variables d'un coin du pays à l'autre. Ces variations représentent un défi supplémentaire dans la mise en place d'un processus d'extraction à l'échelle nationale. Dans ce contexte, le processus devra être robuste et adapté à la zone de travail. L'entraînement de plusieurs algorithmes de *deep learning* sur des sous-zones du pays est suggéré.

## 7 Bibliographie

- AECOM. 2016. *Étude sur le potentiel des données LiDAR pour l'extraction des objets cartographiques autres que l'élévation. Méthodes, outils d'extraction des bâtiments, du réseau hydrographique, des infrastructures de transport et des lignes de transport d'énergie. Rapport présenté à Ressources naturelles Canada.*
- Ahmadi, Salman, MJ Valadan Zoej, Hamid Ebadi, Hamid Abrishami Moghaddam, and Ali Mohammadzadeh. 2010. Automatic urban building boundary extraction from high resolution aerial images using an innovative model of active contours. *International Journal of Applied Earth Observation and Geoinformation* 12 (3): 150-7.
- Ameri, Fateme, and Mohammad J. Valadan Zoej. 2015. Road vectorisation from high-resolution imagery based on dynamic clustering using particle swarm optimisation. *The Photogrammetric Record* 30 (152): 363-86.
- Awrangjeb, Mohammad, Chunsun Zhang, and Clive S. Fraser. 2012. Building detection in complex scenes thorough effective separation of buildings from trees. *Photogrammetric Engineering & Remote Sensing* 78 (7): 729-45.
- Aytekin, Ö., A. Erener, I. Ulusoy, and H. S. B. Düzgün. 2011. Automatic and unsupervised building extraction in complex urban environments from multi spectral satellite imagery.
- Baillard, C., and H. Maître. 1999. 3D reconstruction of urban scenes from aerial stereo imagery: A focusing strategy. *Computer Vision and Image Understanding* 76 (3): 244-58.
- Bélangier, Jean. 2011. Mise à jour de la base de données topographiques du Québec à l'aide d'images à très haute résolution spatiale et du progiciel Sigma0 : Le cas des voies de communication. M. sc. en Géographie., Université de Montréal.
- Campbell, James B., and Randolph H. Wynne. 2011. *Introduction to remote sensing*. 5th ed. New York: Guildford Press.
- Caselles, Vicent, and Pascal Monasse. 2009. Geometric description of images as topographic maps, ser. *Lecture Notes in Mathematics*. Springer-Verlag
- Chan, Tony F., and Luminita A. Vese. 2001. Active contours without edges. *IEEE Transactions on Image Processing* 10 (2): 266-77.
- Chen, Sei-Wang, George C. Stockman, and Kuo-En Chang. 1996. SO dynamic deformation for building of 3D models. *IEEE Transactions on Neural Networks* 7 (2): 374-87.
- Cheng, Guangliang, Ying Wang, Shibiao Xu, Hongzhen Wang, Shiming Xiang, and Chunhong Pan. 2017. Automatic road detection and centerline extraction via cascaded end-to-end convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*.
- Cheng, Guangliang, Feiyun Zhu, Shiming Xiang, Ying Wang, and Chunhong Pan. 2016. Accurate urban road centerline extraction from VHR imagery via multiscale segmentation and tensor voting. *Neurocomputing* 205 : 407-20.
- Contassot-Vivier, Sylvain, Lo Bosco, Giosué, and Nguyen, Chanh D. 1996. *Multiresolution approach for image processing*. Pays-Bas.
- CRIM. CanGeo project. n.d. [cité 06/12 2017]. Available from <http://cangeo.crim.ca/hydro>.
- CRIM. Autocarto, outil pour la détection automatique des contours hydrographiques (ressources naturelles canada). 2017 [cité 06/12 2017]. Available from <http://www.crim.ca/en/achievements/autocarto-a-tool-for-the-automatic-detection-of-hydrographic-contours-form-satellite-images>.
- Dahmane, Mohamed, Samuel Foucher, M. Beaulieu, F. Riendeau, Yacine Bouroubi, and Mathieu Benoit. 2016. Object detection in Pleiades images using deep features. Paper presented at Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International.

- Das, Sukhendu, TT Mirnalinee, and Koshy Varghese. 2011. Use of salient features for the design of a multistage framework to extract roads from high-resolution multispectral satellite images. *IEEE Transactions on Geoscience and Remote Sensing* 49 (10): 3906-31.
- Dillabaugh, Craig R., K. Olaf Niemann, and Dianne E. Richardson. 2002. Semi-automated extraction of rivers from digital imagery. *Geoinformatica* 6 (3) : 263-84.
- Dubois, David. 2014. *Étude du profil d'échelle des formes et de mesures d'énergie de texture pour l'évaluation semi-automatique des dégâts sur les bâtiments dans les images satellitaires de très haute résolution*. Doctorat., École de technologie supérieure.
- Fard, T. Alipour, M. Hasanlou, and H. Arefi. 2014. Classifier fusion of high-resolution optical and synthetic aperture radar (SAR) satellite imagery for classification in urban area. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 40 (2): 25.
- Feyisa, Gudina L., Henrik Meilby, Rasmus Fensholt, and Simon R. Proud. 2014. Automated water extraction index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment* 140 : 23-35.
- Flouzat, Guy, Olivier Amram, Florence Laporterie, and Selma Cherchali. 2001. Multiresolution analysis and reconstruction by a morphological pyramid in the remote sensing of terrestrial surfaces. *Signal Processing* 81 (10): 2171-85.
- Fradkin, M., H. Maître, and M. Roux. 2001. Building detection from multiple aerial images in dense urban areas. *Computer Vision and Image Understanding* 82 (3): 181-207.
- Fraser, C. S., E. Baltsavias, and A. Gruen. 2002. Processing of IKONOS imagery for submetre 3D positioning and building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing* 56 (3) (4): 177-94.
- Ghanea, Mohsen, Payman Moallem, and Mehdi Momeni. 2016. Building extraction from high-resolution satellite images in urban areas: Recent methods and strategies against significant challenges. *International Journal of Remote Sensing* 37 (21): 5234-48.
- Gobron, Nadine, Bernard Pinty, Michel M. Verstraete, and J-L Widlowski. 2000. Advanced vegetation indices optimized for upcoming sensors: Design, performance, and applications. *IEEE Transactions on Geoscience and Remote Sensing* 38 (6): 2489-505.
- Gonzalez, Rafael C., and Richard E. Woods. 2008. *Digital image processing*. 3rd ed. Upper Saddle River, N.J: Pearson Prentice Hall.
- Greenhill, Darrel R., Lennart T. Ripke, Adrian P. Hitchman, Graeme A. Jones, and Graeme G. Wilkinson. 2003. Characterization of suburban areas for land use planning using landscape ecological indicators derived from ikonos-2 multispectral imagery. *IEEE Transactions on Geoscience and Remote Sensing* 41 (9): 2015-21.
- He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. 2016. Deep residual learning for image recognition. Paper presented at Proceedings of the IEEE conference on computer vision and pattern recognition.
- Hermosilla, Txomin, Luis A. Ruiz, Jorge A. Recio, and Javier Estornell. 2011. Evaluation of automatic building detection approaches combining high resolution images and LiDAR data. *Remote Sensing* 3 (6): 1188-210.
- Hong, Seunghwan, Hyoseon Jang, Namhoon Kim, and Hong-Gyoo Sohn. 2015. Water area extraction using RADARSAT SAR imagery combined with landsat imagery and terrain information. *Sensors* 15 (3): 6652-67.
- Huang, Xin, and Liangpei Zhang. 2012. Morphological building/shadow index for building extraction from high-resolution imagery over urban areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5 (1): 161-72.
- Huang, Xin, and Liangpei Zhang. 2009. Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines. *International Journal of Remote Sensing* 30 (8): 1977-87.
- Hunt, E. Raymond, CST Daughtry, Jan UH Eitel, and Dan S. Long. 2011. Remote sensing leaf chlorophyll content using a visible band index. *Agronomy Journal* 103 (4): 1090-9.

- Izadi, Mohammad, and Parvaneh Saeedi. 2010. Automatic building detection in aerial images using a hierarchical feature based image segmentation. Paper presented at 20th International Conference on Pattern Recognition (ICPR).
- Jia, Yangqing, Evan Shelhamer, Jeff Donahue, Sergey Karayev, Jonathan Long, Ross Girshick, Sergio Guadarrama, and Trevor Darrell. 2014. Caffe: Convolutional architecture for fast feature embedding. Paper presented at Proceedings of the 22nd ACM international conference on Multimedia.
- Jiang, N., JX Zhang, HT Li, and XG Lin. 2008. Semi-automatic building extraction from high resolution imagery based on segmentation. Paper presented at International Workshop on Earth Observation and Remote Sensing Applications, 2008. EORSA 2008.
- Jin, Xiaoying, and Curt H. Davis. 2005. Automated building extraction from high-resolution satellite imagery in urban areas using structural, contextual, and spectral information. *Eurasip Journal on Applied Signal Processing* 2005 (14): 2196-206.
- Johnson, Andrew L. DeepoSM. 2016 [cité 09/25 2017]. Available from <https://github.com/trailbehind/DeepOSM>.
- Joshi, Neha, Matthias Baumann, Andrea Ehammer, Rasmus Fensholt, Kenneth Grogan, Patrick Hostert, Martin Rudbeck Jepsen, *et al.* 2016. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing* 8 (1).
- Jung, Claudio Rosito, and Rodrigo Schramm. 2004. Rectangle detection based on a windowed hough transform. Paper presented at 17th Brazilian Symposium on Computer Graphics and Image Processing, 2004. Proceedings.
- Karantzalos, Konstantinos, and Nikos Paragios. 2009. Recognition-driven two-dimensional competing priors toward automatic and accurate building detection. *IEEE Transactions on Geoscience and Remote Sensing* 47 (1): 133-44.
- Khurshid, M. Hasnat, and Muhammad Faisal Khan. 2012. River extraction from high resolution satellite images. Paper presented at Image and Signal Processing (CISP), 2012 5th International Congress on.
- Li, Bangyu, Hui Zhang, and Fanjiang Xu. 2014. Water extraction in high resolution remote sensing image based on hierarchical spectrum and shape features. Paper presented at IOP Conference Series: Earth and Environmental Science.
- Li, Hui, Cheng Zhong, Xiaoguang Hu, Long Xiao, and Xianfeng Huang. 2013. New methodologies for precise building boundary extraction from LiDAR data and high resolution image. *Sensor Review* 33 (2): 157-65.
- Li, Mengmeng, Alfred Stein, Wietske Bijker, and Qingming Zhan. 2016. Urban land use extraction from very high resolution remote sensing imagery using a Bayesian network. *ISPRS Journal of Photogrammetry and Remote Sensing* 122 : 192-205.
- Liasis, Gregoris, and Stavros Stavrou. 2016. Building extraction in satellite images using active contours and colour features. *International Journal of Remote Sensing* 37 (5): 1127-53.
- Liu, Li, and Samsung Lim. 2016. A framework of road extraction from airborne lidar data and aerial imagery. *Journal of Spatial Science* 61 (2): 263-81.
- Long, Jonathan, Evan Shelhamer, and Trevor Darrell. 2015. Fully convolutional networks for semantic segmentation. Paper presented at Proceedings of the IEEE conference on computer vision and pattern recognition.
- Maboudi, Mehdi, Jalal Amini, Michael Hahn, and Mehdi Saati. 2017. Object-based road extraction from satellite images using ant colony optimization. *International Journal of Remote Sensing* 38 (1): 179-98.
- Maboudi, Mehdi, Jalal Amini, Michael Hahn, and Mehdi Saati. 2016. Road network extraction from VHR satellite images using context aware object feature integration and tensor voting. *Remote Sensing* 8 (8).
- Massalabi, Amani, Dong-Chen He, Goze B. Benie, and Eric Beaudry. 2004. Detecting information under and from shadow in panchromatic Ikonos images of the city of Sherbrooke. Paper presented at 2004 IEEE International Geoscience and Remote Sensing Symposium, 2004. IGARSS'04. Proceedings.

- McFEETERS, S. K. 1996. The use of the normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17 (7) (05/01): 1425-32.
- Mokhtarzade, M., and M. J. Valadan Zoej. 2007. Road detection from high-resolution satellite images using artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation* 9 (1): 32-40.
- Motohka, Takeshi, Kenlo Nishida Nasahara, Hiroyuki Oguma, and Satoshi Tsuchida. 2010. Applicability of green-red vegetation index for remote sensing of vegetation phenology. *Remote Sensing* 2 (10): 2369-87.
- Myint, Soe W., Patricia Gober, Anthony Brazel, Susanne Grossman-Clarke, and Qihao Weng. 2011. *Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery*. Vol. 115.
- Navab, Nassir, Joachim Hornegger, William M. Wells, and Alejandro F. Frangi. 2015. Medical image computing and computer-assisted intervention – MICCAI 2015: 18th international conference munich, germany, october 5-9, 2015 proceedings, part II.
- Navulur, Kumar. 2007. *Multispectral image analysis using the object-oriented paradigm*. Boca Raton: CRC Press/Taylor & Francis.
- Pham, Thi-Thanh-Hiên, Philippe Apparicio, Anne-Marie Séguin, and Martin Gagnon. 2011. Mapping the greenscape and environmental equity in Montreal: An application of remote sensing and GIS. In *Mapping environmental issues in the city*. 30-48Springer
- Reichelt, Tim. Waternet. 2017 [cité 08/22 2017]. Available from <https://github.com/treigerm/WaterNet>.
- Rottensteiner, Franz, John Trinder, Simon Clode, and Kurt Kubik. 2007. Building detection by fusion of airborne laser scanner data and multi-spectral images: Performance evaluation and sensitivity analysis. *ISPRS Journal of Photogrammetry and Remote Sensing* 62 (2): 135-49.
- Rougier, Simon, Anne Puissant, André Stumpf, and Nicolas Lachiche. 2016. Comparison of sampling strategies for object-based classification of urban vegetation from very high resolution satellite images. *International Journal of Applied Earth Observation and Geoinformation* 51 : 60-73.
- Rouse Jr, JW, RH Haas, JA Schell, and DW Deering. 1974. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication* 351 : 309.
- San, D. Koc, and M. Turker. 2010. Building extraction from high resolution satellite images using hough transform. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science* 38 (Part 8).
- Scott, Grant J., Matthew R. England, William A. Starns, Richard A. Marcum, and Curt H. Davis. 2017. Training deep convolutional neural networks for Land-Cover classification of high-resolution imagery. *IEEE Geoscience and Remote Sensing Letters* 14 (4): 549-53.
- Shahi, Kaveh, Helmi Zulhaidi Mohd Shafri, and Alireza Hamedianfar. 2016. Road condition assessment by OBIA and feature selection techniques using very high-resolution WorldView-2 imagery. *Geocarto International*: 1-18.
- Shamaoma, H., N. Kerle, and D. Alkema. 2006. Extraction of flood-modelling related base-data from multi-source remote sensing imagery. Paper presented at ISPRS mid-term symposium.
- Shi, Wenzhong, Zelang Miao, and Johan Debayle. 2014. An integrated method for urban main-road centerline extraction from optical remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing* 52 (6): 3359-72.
- Sirmacek, Beril, and Cem Unsalan. 2011. A probabilistic framework to detect buildings in aerial and satellite images. *IEEE Transactions on Geoscience and Remote Sensing* 49 (1): 211-21.
- Sohn, Gunho, and Ian Dowman. 2007. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing* 62 (1): 43-63.

- Sun, Fangdi, Wanxiao Sun, Jin Chen, and Peng Gong. 2012. Comparison and improvement of methods for identifying waterbodies in remotely sensed imagery. *International Journal of Remote Sensing* 33 (21): 6854-75.
- Szegedy, Christian, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. 2015. Going deeper with convolutions. Paper presented at Proceedings of the IEEE conference on computer vision and pattern recognition.
- Tucker, Compton J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* 8 (2): 127-50.
- Tunay, M., MA Marangoz, S. Karakis, and A. Atesoglu. 2007. Detecting urban vegetation from different images using an object-based approach in Bartın, Turkey. Paper presented at Recent Advances in Space Technologies, 2007. RAST'07.
- Van Delm, An, and Hubert Gulinck. 2011. Classification and quantification of green in the expanding urban and semi-urban complex: Application of detailed field data and IKONOS-imagery. *Ecological Indicators* 11 (1): 52-60.
- Wang, Hua, Li Pan, and Hong Zheng. 2008. Multi-texture-model for water extraction based on remote sensing image. Paper presented at Congress on Image and Signal Processing, 2008. CISP'08.
- Wang, Jun, Jingwei Song, Mingquan Chen, and Zhi Yang. 2015. Road network extraction: A neural-dynamic framework based on deep learning and a finite state machine. *International Journal of Remote Sensing* 36 (12): 3144-69.
- Wu, Hangbin, Chun Liu, Yunling Zhang, Weiwei Sun, and Weiyue Li. 2013. Building a water feature extraction model by integrating aerial image and lidar point clouds. *International Journal of Remote Sensing* 34 (21): 7691-705.
- Xie, Cong, Xin Huang, Wenxian Zeng, and Xing Fang. 2016. A novel water index for urban high-resolution 8-band WorldView-2 imagery. *International Journal of Digital Earth* 9 (10): 925-41.
- Xu, Hanqiu. 2006. Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing* 27 (14): 3025-33.
- Yang, Fan, Jianhua Guo, Hai Tan, and Jingxue Wang. 2017. Automated extraction of urban water bodies from ZY-3 Multi-Spectral imagery. *Water* 9 (2): 144.
- Yao, Fangfang, Chao Wang, Di Dong, Jiancheng Luo, Zhanfeng Shen, and Kehan Yang. 2015. High-resolution mapping of urban surface water using ZY-3 multi-spectral imagery. *Remote Sensing* 7 (9): 12336-55.
- Yuan, Jiange. 2016. Automatic building extraction in aerial scenes using convolutional networks. *ArXiv Preprint arXiv:1602.06564*.
- Zaremba, Marek B. 2011. Automated mapping of hydrographic systems from satellite imagery using self-organizing maps and principal curves. In *Self-organizing maps-applications and novel algorithm design*. InTech.
- Zhai, Ke, Xiaoqing Wu, Yuanwei Qin, and Peipei Du. 2015. Comparison of surface water extraction performances of different classic water indices using OLI and TM imagery in different situations. *Geo-Spatial Information Science* 18 (1): 32-42.
- Zhan, Qingming, Martien Molenaar, and Klaus Tempfli. 2002. Hierarchical image object-based structural analysis toward urban land use classification using high-resolution imagery and airborne LIDAR data. Paper presented at Proceedings of the 3rd international conference on remote sensing of urban areas, Istanbul, Turkey.
- Zhang, Xiuying, Xuezhi Feng, and Hong Jiang. 2010. Object-oriented method for urban vegetation mapping using IKONOS imagery. *International Journal of Remote Sensing* 31 (1): 177-96.
- Zhou, Yuhong, and Fang Qiu. 2015. Fusion of high spatial resolution WorldView-2 imagery and LiDAR pseudo-waveform for object-based image analysis. *ISPRS Journal of Photogrammetry and Remote Sensing* 101 : 221-32.

## Annexe I - Compendium des méthodes

Cette section explique des concepts utilisés en traitement d'image. Elle contient de l'information sur des concepts récurrents dans la littérature ainsi que sur certains algorithmes d'apprentissage automatique.

### Concepts généraux

- **Segmentation multirésolution**

La segmentation est la première étape d'une classification orientée-objet. Elle permet de créer dans l'image des zones homogènes qui regroupent les éléments semblables (Shahi *et al.*, 2016). La segmentation multirésolution est une méthode de segmentation largement utilisée et est implantée dans la plupart des outils et logiciels de traitement d'images. Les paramètres de cet algorithme sont : la forme, la compaction et l'échelle. Le paramètre de forme détermine si l'on désire favoriser la forme de l'objet par rapport à l'homogénéité spectrale. La compaction permet de contrôler la préférence sur les contours des objets entre compact et lisse. Finalement, le paramètre d'échelle permet de déterminer la taille des objets segmentés. Un nombre élevé d'échelles va générer de grands objets homogènes alors qu'une petite valeur d'échelle donnera de petits regroupements (Myint *et al.*, 2011).

- **Segmentation Mean Shift**

Le *mean shift* utilise le voisinage des pixels pour regrouper les éléments ayant des valeurs semblables (Dubois, 2014). La forme et le nombre de regroupements ne sont pas fixés par l'utilisateur lors de l'exécution de l'algorithme. Le principe général de fonctionnement comprend trois étapes. Premièrement, une fenêtre est placée autour d'un pixel de l'image. La taille de la fenêtre est spécifiée par l'utilisateur. Ensuite, l'algorithme calcule la moyenne des pixels dans la fenêtre. Finalement, la fenêtre est déplacée vers la moyenne et l'algorithme recommence la première étape jusqu'à la convergence entre la moyenne et les points du regroupement (Thirumuruganathan, 2010).

- **Tensor Voting**

En extraction, il arrive souvent que l'information extraite soit incomplète et bruitée. Le *tensor voting* permet de compléter l'extraction. Les objectifs de l'algorithme sont les suivants : identifier les valeurs aberrantes (bruit) pour les éliminer, estimer la dimension des structures géométriques décrites par les données, estimer l'orientation des structures géométriques et permettre une reconstruction précise de ces structures. Le fondement mathématique de cet algorithme est assez complexe, mais son application est plutôt simple puisque seul le paramètre d'échelle est contrôlé par l'utilisateur (Milkers, 2015 ; Medioni *et al.*, 2000).

- **Chi carré**

Le Chi carré est un test statistique permettant de déterminer si la différence entre deux distributions est statistiquement significative ou simplement attribuable au hasard. La formule du Chi carré est la suivante :

$$\chi_c^2 = \sum \frac{(\text{Observé} - \text{Attendu})^2}{\text{Attendu}}$$

Équation 1 - Chi carré (adapté de Hopkins, 2017).

- **Kappa**

La valeur de kappa est utilisée lors de l'évaluation des résultats de classification. Ce calcul ajuste la précision globale de la classification afin d'éliminer la composante « chance » de la classification (Campbell et Wynne, 2011). L'équation de kappa s'écrit comme suit :

$$\kappa = \frac{\text{Observé} - \text{Attendu}}{1 - \text{Attendu}}$$

Équation 2 - Kappa (adapté de Campbell et Wynne, 2011).

La valeur de kappa varie entre -1 et 1 où -1 indique que la classification donne des résultats pire qu'une classification aléatoire, une valeur de 0 indique que la classification n'est pas meilleure qu'une classification aléatoire et une valeur de 1 indique que la classification est significativement meilleure qu'une classification aléatoire (Campbell et Wynne, 2011).

- **Classification K-Means**

L'algorithme de classification *K-Means* regroupe, de manière itérative, les ensembles de données ayant des similarités. AECOM (2016) propose la définition suivante : « *Le partitionnement en K-moyennes (ou K-means) est une méthode de partitionnement de données et un problème d'optimisation combinatoire. Étant donné des points et un entier K, le problème est de diviser les points en K partitions, souvent appelés clusters [noyau], de façon à minimiser une certaine fonction. On considère la distance d'un point à la moyenne des points de son cluster ; la fonction à minimiser est la somme des carrés de ces distances.* »

## Apprentissage automatique - *Machine Learning*

Les méthodes d'apprentissage automatiques existent depuis les années 80, mais leur application demande une capacité de calcul importante qui est disponible depuis peu. Plusieurs auteurs se sont intéressés à l'application de ces méthodes pour l'extraction d'information à partir d'imagerie satellitaire HR (LeCun *et al.*, 2015).

- **Réseau de neurones artificiels (ANN)**

Le réseau de neurones artificiels comporte une phase d'entraînement (ou apprentissage) et une phase d'exécution. Lors de la phase d'entraînement, l'algorithme parcourt les images, sachant exactement ce qu'il doit rechercher (Mokhtarzade *et al.*, 2007). Ces paramètres de recherche sont appelés neurones. À chaque itération, l'algorithme ajuste et renforce les neurones ainsi que les connexions entre eux afin de réduire l'erreur de détection. Par exemple, si l'on souhaite extraire les routes à partir d'imagerie, on doit fournir à l'algorithme des images sur lesquelles tout ce qui n'est pas une route est masqué. L'algorithme va donc parcourir l'image afin de confirmer, valider et ajuster les paramètres de recherches. Ces algorithmes tentent de recréer le mode d'apprentissage humain par renforcement et associations répétées (Campbell et Wynne, 2011). La taille du réseau (nombre de neurones) est déterminée par l'utilisateur. Un trop petit nombre de neurones peut limiter l'algorithme dans la reconnaissance de motifs importants alors qu'un trop grand nombre peut avoir pour effet de subdiviser les motifs importants de sorte qu'ils deviennent non distinguables (Zaremba, 2011). Pour obtenir de bons résultats, un algorithme doit faire beaucoup d'itérations avec beaucoup de données d'entraînements

(LeCun *et al.*, 2015). La phase d'exécution consiste finalement à appliquer l'algorithme entraîné sur la zone étudiée.

- **Self-Organizing Map (SOM)**

Les SOM sont des types de réseau de neurones artificiels dont l'entraînement est fait automatiquement et sans supervision. C'est-à-dire que les connexions sont déterminées par l'algorithme lui-même. Tout comme dans le réseau de neurones, l'information fournie est pleinement connectée aux couches de neurones et à chaque itération, les connexions entre les neurones sont ajustées et renforcées par l'algorithme (Gao, 2009). L'entraînement se fait par un processus compétitif entre les neurones. À la vue de certains motifs, certains neurones vont réagir de manière plus forte que d'autres. À chaque itération, le neurone ayant la plus grande réaction devient le neurone « gagnant » et ses connexions sont renforcées dans le réseau (Gao, 2009).

- **Réseau de neurones convolutifs (*Convolutional neural network*)**

Traditionnellement, le réseau de neurones convolutifs (ConvNet) est utilisé dans le domaine de la reconnaissance faciale et de l'intelligence artificielle. Il est composé d'une série d'opérations : convolution, opérations non linéaires (ReLU) et ré-échantillonnage (pooling) (Cheng *et al.*, 2017 ; Karn, 2016). Les opérations de convolutions sont des opérations linéaires simples comme des filtres (gaussien, détection de contours, normalisés, etc.). Les opérations non linéaires (polynomiales), quant à elles, sont appliquées pixel par pixel et permettent d'augmenter la complexité du modèle, en y intégrant de la non-linéarité (Long *et al.*, 2015). Le ré-échantillonnage spatial permet de réduire ou augmenter la dimension de l'image tout en gardant un maximum d'information. Finalement, un réseau de neurones artificiels, utilisant les résultats des opérations précédentes, permet au ConvNet de classifier les éléments de l'image (Karn, 2016). Tout comme le réseau de neurones artificiels, le ConvNet possède une phase d'entraînement et une phase d'exécution. L'apprentissage se fait en ajustant les filtres de convolutions de manière à réduire la différence entre la valeur prédite et la valeur réelle des données d'entraînements (Muruganandham, 2016). Le ConvNet a moins de paramètres que le réseau de neurones artificiels à cause de la connectivité locale entre les couches (Cheng *et al.*, 2017).

- **Intelligence distribuée (*Swarm Intelligence*)**

Les algorithmes d'intelligence distribuée tirent leur concept des espèces animales. Ils tentent de représenter les interactions et comportements collectifs que l'on retrouve dans la nature comme ceux des abeilles et des fourmis. De manière générale, l'algorithme va disposer des individus de la colonie sur l'image et le déplacement ainsi que les interactions simulent le comportement des individus de l'essaim (Maboudi *et al.*, 2017).

- **Machines à vecteurs de support (*Support Vector Machine [SVM]*)**

Méthode d'apprentissage supervisé qui est très utilisée pour la classification. Les SVM sont utilisés pour régler les problèmes de discrimination et de régression (AECOM, 2016). Afin de séparer les classes, le SVM tente de trouver l'expression linéaire optimale qui distingue les classes. Dans la mesure où les données ne peuvent être séparées linéairement, l'algorithme va transformer l'information dans un espace de dimension  $X$  (possiblement infinie) où les données peuvent être séparées linéairement (Raschka, 2016).

- **Apprentissage actif (*Active Learning*)**

L'apprentissage actif est un cas d'apprentissage automatique semi-supervisé. Les algorithmes appartenant à cette catégorie affinent leur apprentissage en questionnant de manière interactive l'utilisateur (Rougier *et al.*, 2016). Plusieurs stratégies peuvent être utilisées pour questionner l'utilisateur. Parmi ces stratégies, on note les deux suivantes : le modèle n'est pas certain de la classification et il y a une divergence dans les résultats de classification effectuée par plusieurs modèles.

## Bibliographie du compendium

- Campbell, James B., and Randolph H. Wynne. 2011. *Introduction to remote sensing*. 5th ed. New York: Guildford Press.
- Chan, Tony F., and Luminita A. Vese. 2001. Active contours without edges. *IEEE Transactions on Image Processing* 10 (2): 266-77.
- Cheng, Guangliang, Ying Wang, Shibiao Xu, Hongzhen Wang, Shiming Xiang, and Chunhong Pan. 2017. Automatic road detection and centerline extraction via cascaded end-to-end convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*.
- Cheng, Guangliang, Ying Wang, Shibiao Xu, Hongzhen Wang, Shiming Xiang, and Chunhong Pan. 2017. Automatic road detection and centerline extraction via cascaded end-to-end convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*.
- Dubois, David. 2014. *Étude du profil d'échelle des formes et de mesures d'énergie de texture pour l'évaluation semi-automatique des dégâts sur les bâtiments dans les images satellitaires de très haute résolution*. Doctorat., École de technologie supérieure.
- Gao, Jay. 2009. *Digital analysis of remotely sensed imagery*. New York: McGraw Hill.
- Hopkins, Johns. Statistics how to. 2017 [cited 09/25 2017]. Available from <http://www.statisticshowto.com/probability-and-statistics/chi-square/>.
- Karn, Ujjwal. An intuitive explanation of convolutional neural networks . 2016 [cité 05/23 2017]. Available from <https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/>.
- LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. 2015. Deep learning. *Nature* 521 (7553): 436-44.
- Long, Jonathan, Evan Shelhamer, and Trevor Darrell. 2015. Fully convolutional networks for semantic segmentation. Paper presented at Proceedings of the IEEE conference on computer vision and pattern recognition.
- Maboudi, Mehdi, Jalal Amini, Michael Hahn, and Mehdi Saati. 2017. Object-based road extraction from satellite images using ant colony optimization. *International Journal of Remote Sensing* 38 (1): 179-98.
- Medioni, Gérard, Chi-Keung Tang, and Mi-Suen Lee. 2000. Tensor voting: Theory and applications. Paper presented at Proceedings of RFIA.
- Milkers, S. Lecture 05 gerard medioni - tensor voting: Fundamentals and recent progress. 2015 [cited 07/10 2017]. Available from <https://www.slideshare.net/milkers/lecture-05-gerard-medioni-tensor-voting-fundamentals-and-recent-progress>.
- Mokhtarzade, M., and M. J. Valadan Zoej. 2007. Road detection from high-resolution satellite images using artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation* 9 (1): 32-40.
- Muruganandham, Shivaprakash. 2016. Semantic segmentation of satellite images using deep learning.
- Raschka, Sebastian. 2016. Maximum margin classification with support vector machines . In *Python machine learning*. 71-80Packt Publishing Ltd.
- Shahi, Kaveh, Helmi Zulhaidi Mohd Shafri, and Alireza Hamedianfar. 2016. Road condition assessment by OBIA and feature selection techniques using very high-resolution WorldView-2 imagery. *Geocarto International*: 1-18.
- Thirumuruganathan, Saravanan. Introduction to mean shift algorithm. 2010 [cited 07/07 2017]. Available from <https://saravananthirumuruganathan.wordpress.com/2010/04/01/introduction-to-mean-shift-algorithm/>.

Zaremba, Marek B. 2011. Automated mapping of hydrographic systems from satellite imagery using self-organizing maps and principal curves. In *Self-organizing maps-applications and novel algorithm design*. InTech.