

Approche orientée objet sémantique et coopérative pour la classification des images de zones urbaines à très haute résolution

Aymen Sellaouti^{*,**}, Atef Hamouda^{*}
Aline Deruyver^{**}, Cedric Wemmert^{**}

^{*}Faculté des Sciences de Tunis, Tunis, Tunisie - LIPAH
aymen.sellaouti@gmail.com

^{**}Université de Strasbourg - LSIIT
Pôle API, Bd Sébastien Brant - 67412 Illkirch, France
Aline.Deruyver@lsiit.u-strasbg.fr,

^{*}Atef_Hamouda@yahoo.fr
^{**}wemmert@unistra.fr

Résumé. La classification orientée objet (COO) prend de plus en plus de dimension dans les travaux de télédétection grâce à sa capacité d'intégrer des connaissances de haut niveau telles que la taille, la forme et les informations de voisinage. Cependant, les approches existantes restent tributaires de l'étape de construction des objets à cause de l'absence d'interaction entre celle-ci et celle de leur identification. Dans cet article, nous proposons une approche sémantique, hiérarchique et collaborative entre les algorithmes de croissances de régions et une classification orientée objet supervisée, permettant une coopération entre l'extraction et l'identification des objets de l'image. Les expériences menées sur une image de très haute résolution de la région de Strasbourg ont confirmé l'intérêt de l'approche introduite.

1 Introduction

La classification des images satellitaires haute résolution est de plus en plus complexe. La complexité et l'hétérogénéité des données satellitaires haute résolution ne permettent plus l'utilisation des méthodes de classification pixélique. En effet, quoi qu'elle permette d'offrir dans certains cas un résultat qui reflète de manière fidèle la réalité du terrain étudié, elle reste tributaire d'une conformité, d'une répartition homogène des classes recensées et d'une bonne stabilité radiométrique des zones d'apprentissage. Lesquelles sont aussi limitées du point de vue caractéristique. Ces difficultés ont catalysé la recherche de nouvelles approches d'analyse d'image exploitant mieux les informations présentes dans l'image ainsi que les connaissances expertes qui peuvent être une source de connaissances très fructueuse Sellaouti et al. (2012b). Dans ce sens, l'analyse d'image basée objets semble être prometteuse Blaschke (2010). En effet, elle permet de converger d'un espace image composé de pixel vers un espace objet ou chaque objet représente une entité homogène selon des critères bien définis ce qui permet

Classification orientée objet sémantique

d'avoir une vue plus globale de l'image. Le deuxième avantage de cette approche objet est qu'elle reste propice à l'intégration des connaissances expertes grâce à sa capacité d'intégrer des connaissances de haut niveau telles que la taille, la forme et les connaissances spatiales ce qui permet de diminuer le gap sémantique.

La classification orientée objet est une approche composée de deux étapes dont la première consiste à la construction des objets et qui est généralement une segmentation. La deuxième étape est l'identification des objets extraits. La classification orientée objet se base sur les régions extraites lors de la phase de segmentation mais aucune interactivité n'existe entre ces deux processus. Cette classification utilise directement les régions extraites lors de la première étape sans mettre en cause la segmentation. Cependant, une région mal segmentée est généralement mal classée. Ceci s'explique par le fait qu'elle se base sur des caractéristiques qui peuvent être erronées. Une remise en cause de la segmentation par la classification et une collaboration entre eux s'impose.

Dans cet article, nous proposons une approche orientée objet sémantique collaborative permettant une collaboration entre les deux étapes d'extraction et d'identification des objets en intégrant des connaissances expertes. En effet, la première étape de l'algorithme permet d'extraire des régions homogènes et de leur assigner un score de confiance. Ce score sera ensuite utilisé pour une croissance de région sémantique dont résultera la classification finale.

Ce papier est organisé comme suit : dans la section 2, nous reviendrons sur différents algorithmes de classification orientée objet proposées dans la littérature. Ensuite, dans la section 3, nous introduisons notre approche. La section 4 sera consacrée à l'étude expérimentale.

2 Etat de l'art des approches de classification orientée-objet

L'approche orientée objet est une approche qui se base sur la création d'un ensemble de régions représentant les objets de l'image afin de les classer. Plusieurs travaux ont été présentés dans la littérature. Nous proposons de décomposer ces approches en trois classes : approche naturelle, approche hiérarchique et approche collaborative. Nous présentons dans ce qui suit, un aperçu sur ces travaux.

2.1 Approche naturelle

L'approche naturelle repose sur la structure classique de la classification orientée-objet qui est composée d'une phase de segmentation de l'image en un ensemble d'objets suivi d'une classification de ces objets. Walter (2004) présente une approche pour la détection des changements apparus dans les zones urbaines. Il propose une approche divisée en deux parties, la première consiste en une classification supervisée avec l'algorithme de maximum de vraisemblance. La base d'apprentissage est extraite à partir d'une base GIS existante. Dans la deuxième partie, une mise en correspondance entre les objets classés et les objets existants dans la base GIS est appliquée pour détecter les changements. L'auteur utilise toutes les bandes spectrales. Les caractéristiques utilisées sont des caractéristiques spectrales et texturales. Ericksson (2004) utilise une approche orientée objet pour détecter les couronnes d'arbres. En effet, il commence par une segmentation qui va lui permettre de détecter les couronnes d'arbres. Cette segmentation est la croissance de région par mouvement Brownien. Une fois les couronnes des arbres

détectées, Ericksson procède à une classification de ces couronnes en se basant sur un ensemble de règles spécifiques à chaque classe. La couronne qui vérifie les règles d'une classe est affectée à cette dernière. Bendhiaf et Sellaouti (2009), utilisent les couronnes extraites par l'algorithme de croissance de région pour procéder à une classification basée sur les indices de formes et la texture. Lefebvre et al. (2011) présentent une classification orientée-objet basée sur les ondelettes et la théorie des évidences. Une première étape de segmentation utilisant la ligne de Partage des Eaux (LPE) est utilisée sur une image de contours créée à partir des composantes horizontales et verticales de la décomposition en ondelettes afin d'éviter un résultat sur-segmenté. Ensuite, une agrégation des petits objets non exploitables dans l'étape suivante est effectuée en fusionnant les régions voisines de petite taille et de valeur moyenne de luminance proche. La deuxième étape est la caractérisation des objets extraits avec des attributs de luminance et de texture. La dernière étape est la classification basée sur la théorie de l'évidence en fusionnant les critères de similarité de luminance et de texture.

2.2 Approche hiérarchique

Cette approche utilise une représentation multi-échelle de l'image. En effet, elle repose sur une segmentation multi-échelle, l'image est donc représentée par une famille d'images allant de la perception de l'image la plus fine vers la plus grossière.

Hofmann (2001) présente une approche orientée objet pour la classification des zones urbaines, ils présentent deux approches utilisées par le logiciel eCognition pour extraire les objets d'intérêt. Le départ de l'approche est une segmentation multi-échelle qui permet de créer un réseau hiérarchique représentant l'image. La segmentation multi-échelle peut être réalisée de deux façons différentes qui sont Bottom-up et Top-down. L'approche top-down commence par générer les objets du niveau le plus haut. Tous les objets des niveaux le plus bas sont des sous objets du niveau supérieur. L'approche Bottom-up, quant à elle, opère inversement. La segmentation commence par générer les petits objets. Tous les objets générés dans les niveaux plus hauts sont alors considérés comme des super objets du niveau initial. Le logiciel offre deux classifieurs de base : le classifieur des k plus proches voisins et un classifieur flou. Marangoz et al. (2004) utilisent cette approche pour détecter les routes et les bâtiments dans une image IKONOS. Karsenty et al. (2007) utilisent la même approche pour évaluer la perméabilité des sols en zone urbaine à l'aide d'imagerie très haute résolution et de données laser scanner à Curitiba au Brésil. De même, pour Jacquin et al. (2008) qui utilisent cette approche pour voir l'effet de l'expansion urbaine sur les inondations et les anticiper.

2.3 Approche hybride

Giraudon et al. (1992) ont développé le système MESSIE. Ce système est une architecture multi-spécialiste, bâti autour d'une architecture de type tableau noir, dont l'objectif est de réaliser une interprétation basée uniquement sur une connaissance générique des objets sans utiliser de connaissances exogènes à la donnée image. Les auteurs montrent comment une modélisation des objets physiques de la scène exprimée sous les quatre points de vue forme, contexte, aspect et fonction peut améliorer la classification. Ce système est capable de manipuler des connaissances ponctuelles (informations radiométriques) et structurelles (propriétés géométriques, relations spatiales). Chaque spécialiste a une tâche spécifique et indépendante

des autres spécialistes. Pour communiquer entre eux, les spécialistes utilisent une zone mémoire commune qui est le tableau noir. Plusieurs rôles sont assignés aux spécialistes tels que l'extraction des objets, le calcul des caractéristiques structurelles, l'évaluation des hypothèses, l'étiquetage des objets, la détection des conflits, etc. Le système peut facilement accepter de nouvelles connaissances expertes et de nouveaux spécialistes.

Forestier et al. (2008), quant à eux, proposent une approche orientée objet collaborative et multi-stratégie. Elle intègre un ensemble de classifieurs non supervisés et présente une nouvelle approche qui permet de faire collaborer les différents classifieurs. L'originalité de cette approche est qu'elle intègre le processus de collaboration durant l'étape de classification. En effet, elle est divisée en trois étapes. La première est une classification initiale où chaque classifieur est lancé avec ses propres paramètres, permettant de créer des objets. La deuxième étape consiste en un raffinement des résultats divisés en deux parties à savoir d'une part l'évaluation de la similarité des classes et d'autre part, leur raffinement. La dernière étape est l'unification où les résultats raffinés sont unifiés avec un algorithme de vote.

Pour résumer, toutes les approches décrites ont une limite commune, c'est leur dépendance à la phase de segmentation. En effet, cette phase initiale est la plus importante vu qu'une mauvaise segmentation entraîne nécessairement une mauvaise classification. Dans toutes les approches précitées, l'étape de segmentation n'est jamais mise en cause par la classification.

3 Approche de classification orientée-objet collaborative

Une approche de segmentation qui favorise nettement la notion de collaboration est l'approche région. En effet, son architecture itérative permet d'introduire de nouvelles connaissances le long du processus de segmentation. Dans ce cadre, nous introduisons une approche collaborative entre les algorithmes de croissances de régions et une COO supervisée permettant une collaboration entre les deux étapes d'extraction et d'identification des objets en intégrant des connaissances expertes. Notre approche est composée de deux étapes :

- Une première étape de prétraitement qui est une étape de préparation des données pour l'étape suivante. Elle permet de décomposer l'image en un ensemble de régions homogènes en se basant sur des propriétés bas niveau. Ensuite, une classification initiale va permettre d'assigner un score de confiance pour chacun des objets extraits par la segmentation.
- La deuxième étape est la classification sémantique basée sur une croissance guidée par les scores des régions calculés dans la première étape.

3.1 Prétraitement

3.1.1 Segmentation

Le choix de l'algorithme de segmentation n'est pas très important dans cette approche tant qu'il vérifie le critère de sur-segmentation. En effet, et vues les propriétés des algorithmes de croissances de région qui se basent sur la fusion des fragments d'un objet afin de détecter l'objet tout entier, il est évident qu'une sous-segmentation de l'image implique une perte de certains objets. Le choix de la sur-segmentation s'impose donc. Nous avons ainsi choisi l'al-

gorithme "watershed" qui permet une sur-segmentation de l'image, permettant de déterminer un ensemble de régions de départ, qu'on notera \mathcal{R} .

3.1.2 Classification

Nous proposons ici une classification permettant d'affecter à chacune des régions de \mathcal{R} une classe C en calculant un score de confiance d'appartenance de \mathcal{R} à C , par rapport à l'ensemble des classes présentes dans l'image. Ce score permettra d'évaluer la légitimité des régions en se basant sur les connaissances fournies par l'expert. Nous utilisons le score de similarité proposé par Derivaux et al. (2007). Il est basé sur une approche orientée attribut vu qu'il utilise les connaissances bas niveaux sur l'image qui sont formalisées sous forme de descripteurs bas niveaux. Ce score permet de vérifier la validité des valeurs des attributs d'une région selon les intervalles définis par l'expert dans la base de connaissances. La mesure de similarité locale compare les valeurs des attributs d'une région avec les attributs de l'objet à classer. Nous présentons dans ce qui suit les formules permettant de calculer le score de similarité, précédées par un ensemble de notations nécessaires pour une représentation formelle de l'approche proposée Sellaouti et al. (2012a).

Note 1 (région) : Soit \mathcal{R} l'ensemble des régions r_i obtenu à partir de la segmentation. $\mathcal{R} = \{r_i\}_{i \in [1, N_R]}$ où N_R représente la cardinalité de \mathcal{R} .

Note 2 (classe) : Soit C l'ensemble des classes présentes dans l'image. $C = \{c_j\}_{j \in [1, N_C]}$ où N_C représente la cardinalité de C .

Note 3 (attribut) : Soit A l'ensemble des attributs identifiant une classe. $A = \{a_k\}_{k \in [1, N_k]}$ où N_k représente la cardinalité de A .

Définition 1 (Degré de validité) : Le degré de validité entre une classe c_i et une région r_i pour un attribut a_k , que l'on note $Valid(a_k, c_j, r_i)$, est défini comme suit :

$$Valid(a_k, c_j, r_i) \begin{cases} 1 & \text{si } v(r_i, a_k) \in [\min(c_j, a_k), \max(c_j, a_k)] \\ \frac{v(r_i, a_k)}{\min(c_j, a_k)} & \text{si } v(r_i, a_k) < \min(c_j, a_k) \\ \frac{\max(c_j, a_k)}{v(r_i, a_k)} & \text{si } v(r_i, a_k) > \max(c_j, a_k) \end{cases} \quad (1)$$

où $v(r_i, a_k)$ est la valeur de l'attribut a_k pour la région r_i .

Définition 2 (Score de similarité) : Le score de similarité, noté $Sim(r_i, c_j)$, est calculé en fonction de la validité entre la région r_i et la classe c_j de chaque attribut a_k . Le calcul est pondéré par un poids $w(k, c_j)$, qui permet de gérer l'importance de chaque attribut pour les différentes classes.

La formule du calcul du score de similarité est donc la suivante :

$$Sim(r_i, c_j) = \frac{\sum_{a \in A} w(a_k, c_j) Valid(a_k, c_j, r_i)}{\sum_{a \in A} w(a_k, c_j)} \quad (2)$$

Définition 3 (Ensemble de similarité) : Nous définissons l'ensemble SIM comme étant l'ensemble des scores de similarité de toute région $r_i \in \mathcal{R}$ par rapport à toute classe $c_j \in C$.

$$SIM = \{Sim(r_i, c_j) | r_i \in \mathcal{R} \text{ et } c_j \in C\} \quad (3)$$

3.2 Classification sémantique

Après la phase de prétraitement explicitée ci-dessus, nous procédons à l'étape de classification sémantique qui consiste en un traitement itératif permettant à partir des ensembles de régions \mathcal{R} , de classes \mathcal{C} et de scores de similarité SIM, de créer une hiérarchie de croissances basée sur la confiance en chaque région. La création de la hiérarchie est précédée par un calcul basé sur les scores de similarité que nous explicitons dans ce qui suit.

Pour une région $r_i \in \mathcal{R}$, nous définissons l'ensemble des classes qui maximisent le score de similarité $Sim(r_i, c)$ parmi toutes les classes $c \in \mathcal{C}$. Nous notons $\delta(r_i)$ cet ensemble :

$$\delta(r_i) = \arg \max_{c \in \mathcal{C}} Sim(r_i, c) \quad (4)$$

Définition 4 Pour chaque région $r_i \in \mathcal{R}$, nous définissons $S_{max}(r_i)$ et $C_{max}(r_i)$ comme suit :

$$C_{max}(r_i) = \begin{cases} random(\delta(r_i)) & \text{if } |\delta(r_i)| > 1 \\ \delta(r_i) & \text{sinon} \end{cases} \quad (5)$$

$$S_{max}(r_i) = \begin{cases} Sim(r_i, C_{max}(r_i)) & \text{if } |\delta(r_i)| > 1 \\ 0 & \text{sinon} \end{cases} \quad (6)$$

$S_{max}(r_i)$ représente le score de similarité maximal de la région r_i pour l'ensemble des classes de \mathcal{C} . Dans le cas où $\delta(r_i)$ comporte plus qu'une classe, nous déduisons qu'il y a une confusion et que cette région n'est plus une région de confiance mais une région conflictuelle. Dans ce cas, $C_{max}(r_i)$ prendra arbitrairement l'une des classes de $\delta(r_i)$ et $S_{max}(r_i)$ aura la valeur 0. Dans le cas où l'ensemble contient une valeur unique, alors cette dernière sera affectée à $C_{max}(r_i)$ et $S_{max}(r_i)$ sera le score de similarité $Sim(r_i, C_{max}(r_i))$ de la classe Cmax pour la région r_i et cette région aura comme classe $C_{max}(r_i)$.

Le calcul des $C_{max}(r_i)$ et $S_{max}(r_i)$ servira comme départ pour l'algorithme itératif de la hiérarchie de la classification sémantique que nous proposons. Le diagramme de la figure 1 illustre les étapes de cet algorithme. En effet, chaque itération de cet algorithme concerne un niveau de croissance de la hiérarchie. Chacune de ces itérations est composée de deux phases principales (les phases 1 et 2 du diagramme), à savoir l'extraction des germes et la croissance sémantique. Dans la première phase, nous commençons par extraire les régions de départ que nous appelons germes. Ces derniers représentent les régions de confiances parmi l'ensemble des régions candidates. Ensuite dans la deuxième phase, en se fondant sur des connaissances expertes, et selon la classe d'appartenance du germe, nous procédons à une croissance sémantique à partir des germes déterminés dans la première phase.

Pour une itération k ($k \geq 1$), nous désignerons par $RegionsCandidates_{k-1}$ l'ensemble des régions candidates à l'extraction des germes, par $RegionsContraintes_{k-1}$ l'ensemble des germes déjà traités, par $RegionsGermes_k$ l'ensemble des germes extraits et par $RegionFusionne_k$ l'ensemble des régions fusionnées. Les phases 3 et 4 permettent de mettre à jour les ensembles $RegionsCandidates_k$ et $RegionsContraintes_k$. Nous détaillons dans ce qui suit les deux phases constituant une itération.

3.2.1 Extraction des germes

Le choix des germes de départ est très important pour le processus de la croissance sémantique. Visant à exploiter toutes les informations disponibles et souhaitant converger vers une

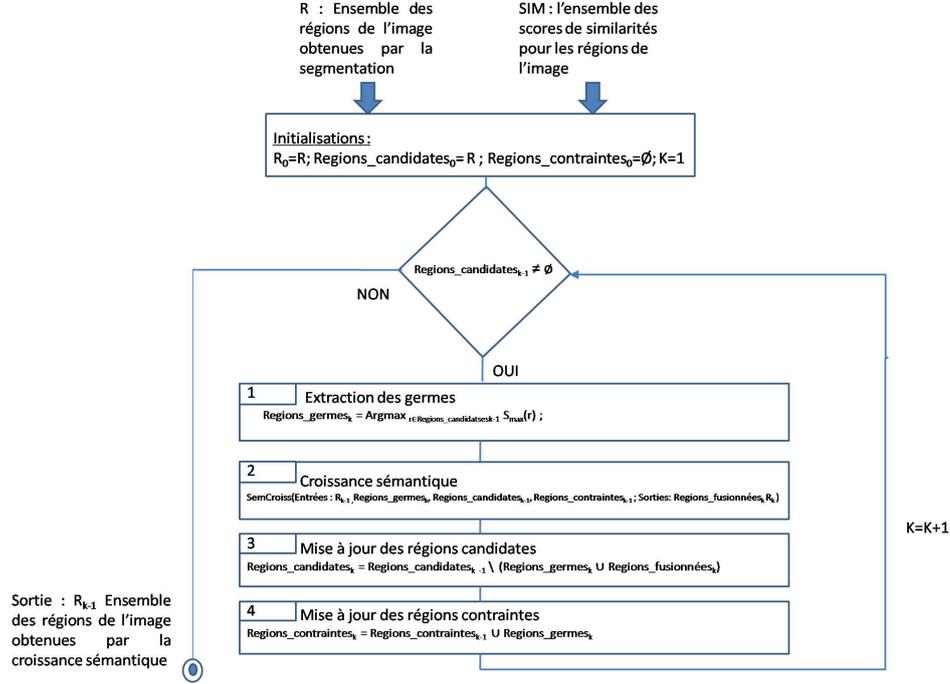


FIG. 1 – Diagramme de croissance de région sémantique.

approche sémantique, le choix des germes reposera sur la confiance que nous avons en les régions non encore traitées dans l'image. L'ensemble des germes de niveau k ($RegionsGerme_k$) sera alors celui qui maximise la confiance et plus précisément le score de similarité. Ces régions seront extraites à partir de l'ensemble $RegionCandidates_{k-1}$ des régions non encore traitées dans les niveaux précédents de la hiérarchie. Les germes extraits à ce niveau sont les régions ri qui maximisent $S_{\text{max}}(ri)$. Nous notons formellement :

$$RegionGerme_k = \arg \max_{r \in RegionCandidates_{k-1}} S_{\text{max}}(r). \quad (7)$$

3.2.2 Croissance sémantique

Nous présentons dans ce qui suit le principe de l'algorithme de croissance sémantique (la fonction *SemCroiss* appelée à la phase 2 du diagramme 1) qui prend comme entrée l'ensemble des germes, des régions candidates à la croissance et des régions contraintes. Il permet la fusion de chaque germe avec ses régions voisines en se fondant sur les connaissances expertes spécifiques à la classe du germe et en prenant en compte les régions contraintes. La croissance sémantique est illustrée par l'algorithme 1.

Cet algorithme itère sur l'ensemble de germes appliquant pour chacun deux fonctions (*ExtraireZoneCroissance* et *Croissance*) mettant en œuvre les deux principaux procédés composant la croissance sémantique, à savoir l'extraction de la zone de croissance dans dans

Algorithme 1 : SemCroiss

Données : *RegionsGerms* l'ensemble des germes, *RegionsCandidates* l'ensemble des candidats pour la croissance et *RegionsContraintes* l'ensemble des régions de contraintes.

Résultats : Fusion, l'ensemble des régions fusionnées lors de la croissance

```

1  début
2  | Fusion =  $\phi$ ;
3  | pour chaque  $r_i \in$  RegionsGerms faire
4  | |    $ZC_{r_i} =$  ExtraireZoneCroissance( $r_i, C_{max}(r_i),$  RegionsCandidates,
5  | | |   RegionsContraintes, Fusion);
6  | | |    $Fusionnees\_avec\_r_i =$  Croissance( $r_i, C_{max}(r_i), ZC_{r_i}$ );
7  | | |    $Fusion = Fusion \cup Fusionnees\_avec\_r_i$ ;
8  | finprch
9  fin

```

un premier lieu et la croissance au sein de cette zone dans un second lieu. Notons que nous nous limiterons dans cet article à la présentation générale de notre approche en faisant abstraction aux types de classes traitées. Or, comme la technique de croissance sémantique que nous proposons est intrinsèquement dépendante des spécificités des classes, nous nous contentons ici de présenter les principes des fonctions ainsi que leurs entrées et sorties :

L'extraction de la zone de croissance : Connaissant la classe du germe, nous proposons de limiter l'espace de croissance en se basant sur les connaissances expertes. En effet, celles-ci permettent dans plusieurs cas de réduire l'ensemble des régions candidates à la fusion. Les connaissances expertes peuvent être représentées de plusieurs manières, telles que les ontologies, les règles logiques, etc. Cette phase est tributaire de la classe traitée. En effet, si nous prenons l'exemple de la classe végétation, rares sont les informations qui peuvent être utiles pour limiter l'espace de recherche. N'ayant ni forme géométrique bien définie, ni superficie limitée, la zone de croissance de cette classe ne peut pas vraiment être limitée. Par contre, si nous prenons l'exemple des classes bâtiment et route, elles possèdent toutes les deux des caractéristiques géométriques et des formes bien définies ce qui permet de limiter l'espace de croissance.

L'appel de la fonction *ZoneCroissance* dans une itération de l'algorithme 1 permet de générer, à partir, d'une région germe r donnée et des régions candidates à la croissance, l'ensemble des régions pertinentes qui peuvent fusionner avec le germe r , que l'on notera ZC_r . Cette fonction prend en considération les régions déjà fusionnées que ce soit pour d'autres germes de l'itération courante (i.e. *Fusion*) ou dans les itérations précédentes (i.e. *RegionsContraintes*). L'ensemble ZC_r serait égal à l'ensemble des candidats privé des régions élaguées dans le cas où la classe $C_{max}(r)$ supporte l'intégration de connaissances expertes comme expliqué précédemment. Dans le cas contraire, ZC_r comporterait toutes les régions candidates sauf celle déjà fusionnée dans l'itération courante (i.e. $ZC_r = RegionCandidates \setminus Fusion$).

Croissance : Contrairement à la croissance de région de base qui utilise les propriétés bas niveau (radiométrie, texture) sans prendre en compte la nature des objets traités, la croissance de région sémantique est, quant à elle, une croissance spécifique pour chaque germe selon sa classe d'appartenance. Prenons l'exemple de la classe route qui possède des pro-

priétés qui la différencient des autres classes. En effet, elle présente une surface homogène, et elle est majoritairement composée d'asphalte et ayant des contours linéaires et parallèles et une largeur variant dans un intervalle bien déterminé. A partir de ces connaissances nous pouvons détecter la zone de croissance de chaque germe en cherchant sa direction et en utilisant les informations sur sa largeur. L'appel de la fonction *Croissance* dans une itération de l'algorithme 1 permet de croître à partir d'un germe r dans la zone de croissance ZC_r . La détermination des régions pertinentes qui peuvent fusionner avec ce germe r dépendra de la classe du germe et des connaissances expertes la concernant. Cette fonction retournerait l'ensemble *Fusionnes_avec_r* des germes fusionnés avec r . L'union de ces ensembles pour chaque itération formerait l'ensemble de retour de l'algorithme SemCroiss.

4 Etude Expérimentale

Afin d'évaluer notre approche, nous avons utilisé une image urbaine très haute résolution de la zone de Strasbourg (France). Cette image a été prise en 2008 par le satellite Quickbird. Elle comporte 4 bandes ayant comme résolution 2.44m/px. Nous avons testé notre approche sur un ensemble d'échantillons dont nous présentons ici deux exemples. La figure 2(a) représente une zone urbaine éparse alors que la figure 2(b) est une zone dense.



FIG. 2 – Zones urbaines de la cité de Strasbourg.

Notre approche est une classification sémantique basée sur les connaissances expertes. Les connaissances que nous avons utilisés sont extraites à partir du dictionnaire de données FODOMUST réalisé par les experts géographes¹. Il a été modélisé sous forme d'une ontologie formée d'une hiérarchie de concepts reliés entre eux par des relations par Derivaux et al. (2007). Chaque concept est défini par une étiquette (e.g. maison, route) et un ensemble d'attributs (e.g. air, forme) ou chaque attribut est associé à un intervalle représentant les valeurs que

1. fourni par le laboratoire LIVE de Strasbourg, France (ERL 7230)

Classification orientée objet sémantique

peut accepter chaque attribut ainsi que d'une valeur de pondération indiquant l'importance de l'attribut.

Nous présentons ici le résultat de classification concernant les classes route et bâtiment. Les figures 3(a) et 3(b) illustrent le résultat d'extraction des routes pour la zone de test éparses et denses alors que les résultats de la classe bâtiment sont illustrés dans les figures 4(a) et 4(b). Nous remarquons que la majorité des bâtiments et des routes présents dans l'image ont été extraits et que la qualité de l'extraction s'avère acceptable pour les images denses et éparses. Cependant, les résultats des zones éparses sont meilleurs. Ceci est prévisible puisque les zones denses présentent plus de bruit.



(a) Zone éparses



(b) Zone dense

FIG. 3 – Classification de la classe route.



(a) Zone éparses



(b) zone dense

FIG. 4 – Classification de la classe bâtiment.

Classes/Mesures	Route	Bâtiment
Rappel	0.8735	0.9424
Précision	0.8528	0.8740

TAB. 1 – *Evaluation.*

L'évaluation numérique confirme l'intérêt de notre approche. Le tableau 1 détaille le résultat des mesures de rappel et de précision pour les deux classes route et bâtiment. Le rappel varie entre 87.35% et 94.24% alors que la précision varie entre 85.28% et 87.40%. Les valeurs de la précision sont inférieures à celles du rappel à cause des erreurs de classification de la phase de prétraitement.

5 Conclusion

Dans cet article, nous avons présenté une nouvelle approche de classification orientée objet collaborative et sémantique. Cette approche essaie de remédier au manque d'interaction entre les deux étapes majeurs de la classification orienté objet à savoir la construction puis l'identification des objets. Notre approche se base sur une hiérarchie de croissance sémantique permettant de détecter des objets selon la confiance calculée pour chaque région de l'image et en se basant sur des connaissances expertes. L'expérimentation de cette approche sur une image Quickbird très haute résolution de la zone de Strasbourg a montré l'intérêt de l'approche. Afin de prouver l'apport de cette approche, nous projetons de traiter les classes existantes dans l'image en intégrant les informations spécifiques à chaque classe à partir du dictionnaire de données FODOMUST.

Références

- Bendhiaf, Z. et A. Sellaouti (2009). Système de classification d'images forestières haute résolution basé sur l'intégration des informations et des connaissances structurelles. In *Proceedings of TAIMA, Hammamet, Tunisie*.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65(1), 2–16.
- Derivaux, S., N. Durand, et C. Wemmert (2007). On the complementarity of an ontology and a nearest neighbour classifier for remotely sensed image interpretation. In *Proceedings of IEEE International Geoscience & Remote Sensing Symposium, IGARSS, Barcelone, Espagne*, pp. 3983–3986. IEEE.
- Ericksson, M. (2004). Species classification of individually segmented tree crowns in high resolution aerial images using radiometric and morphologic image measures. *Remote Sensing of Environment* 91, 469–477.
- Forestier, G., C. Wemmert, et P. Gançarski (2008). On combining unsupervised classification and ontology knowledge. In *Proceedings of IEEE International Geoscience & Remote Sensing Symposium, IGARSS, Boston, Massachusetts, USA*, pp. 395–398.

Classification orientée objet sémantique

- Giraudon, G., P. Garnesson, et P. Montésinon (1992). Messie : a multi expert system in computer vision. application for aerial imagery interpretation. *Traitement du signal* 9(5), 403–419.
- Hofmann, P. (2001). Detecting urban features from ikonos data using an object-oriented approach. *Remote Sensing Photogrammetry Society* 1, 28–33.
- Jacquin, A., L. Misakova, et M. Gay (2008). A hybrid object-based classification approach for mapping urban sprawl in periurban environment. *Landscape and Urban Planning* 84(2), 152–165.
- Karsenty, A., A. Antunes, et J. Centeno (Avril, 2007). Classification orientée objet de la perméabilité des sols en zone urbaine à l'aide d'imagerie très haute résolution et de données laser scanner à curitiba. In *Proceedings of Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Brésil*, pp. 562–572.
- Lefebvre, A., T. Corpetti, et L. Hubert-Moy (2011). Ondelettes et théorie des évidences pour la classification orientée-objet. caractérisation et suivi des changements d'occupation des sols de la métropole de rennes. *Revue Internationale de Géomatique* 21(3), 297–325.
- Marangoz, A., M. Oruc, et G. Buyuksalih (July, 2004). Object-oriented image analysis and semantic network for extracting the roads and buildings from ikonos pan-sharpened images. In *Proceedings of the ISPRS 2004 Annual Conference, Istanbul, Turquie*, pp. 19–23.
- Sellaouti, A., A. Hamouda, A. Deruyver, et C. Wemmert (2012a). Hierarchical classification-based region growing (hcbg) : A collaborative approach for object segmentation and classification. In *Image Analysis and Recognition - 9th International Conference, ICIAR 2012, Aveiro, Portugal.*, pp. 51–60.
- Sellaouti, A., M. OuledSghaier, et A. Hamouda (2012b). An edge-region cooperative multi-agent approach for buildings extraction. In *Proceedings of the The Second International Conference on Digital Information and Communication Technology and its Applications (DICTAP2012), Bangkok, Thailand, Volume 7324*, pp. 51–60.
- Walter, V. (2004). Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing* 58, 225–238.

Summary

Object based image analysis is a rising research area in remote sensing. This is due to its ability to integrate high-level knowledge such as size, shape and neighborhood information. However, existing approaches heavily rely on the object construction process, mainly due to the lack of interaction between the two steps. In this paper, we propose a semantic and collaborative algorithm between growth regions and object-oriented supervised classification allowing cooperation between extraction and identification of objects in the image. Carried out experiments on a Quickbird Strasbourg image show the benefits of the introduced approach.