

# Un cadre collaboratif pour la segmentation et la classification d'images de télédétection

Andrés Troya-Galvis\*, Pierre Gançarski\*  
Laure Berti-Équille\*\*

\*Icube UMR 7357, Université de Strasbourg  
{troyagalvis, gancarski}@unistra.fr,  
\*\*Qatar Computing Research Institute  
lberti@qf.org.qa

**Résumé.** Dans cet article nous présentons CoSC, un cadre collaboratif pour la segmentation et la classification d'images de télédétection permettant d'extraire les objets d'une classe thématique donnée. Le processus de collaboration est guidé par la qualité des données évaluée par des critères d'homogénéité ainsi que des critères implicitement liés à la sémantique des objets afin d'extraire une classe thématique donnée. Nos expériences montrent que CoSC atteint des bons résultats en termes de classification, et améliore notablement la segmentation de l'image de manière globale.

## 1 Introduction

L'interprétation automatique d'images de télédétection est une tâche difficile mais essentielle dans de nombreux domaines d'application, telles que la cartographie forestière (Räsänen et al., 2013), la gestion de risques liés aux glissements de terrain (Promper et al., 2014), ou la planification urbaine (Pham et al., 2011).

Cette interprétation consiste généralement à extraire et à classifier les zones (naturelles, artificialisées, ...) ou les objets d'intérêt (batiments, routes, ...) présents dans la scène.

Pour les images à des résolutions<sup>1</sup> comprises entre 5 et 500 m la classification se fait généralement au niveau des pixels et des valeurs radiométriques de ceux-ci, éventuellement complétées par des informations spatiales ou texturales. Avec les images à très haute résolution spatiale (THR) proche du mètre, les méthodes par pixels ont montré leurs limites : les objets d'intérêt doivent être reconstruits avant analyse.

Les méthodes *orientées objets (ou régions)* (OBIA) construisent ces objets d'intérêt avant de les classifier en utilisant éventuellement des connaissances du domaine (Fig. 1). Ainsi, une image (T)HRS obtenue via un capteur aérien ou satellitaire est corrigée atmosphériquement et géométriquement afin de produire une image prête à l'analyse. Cette image corrigée est alors segmentée et ces segments sont caractérisés par des vecteurs de caractéristiques tels que des indices de forme ou de texture. Enfin des méthodes de classification supervisée ou guidée par des connaissances du domaine sont appliquées afin d'obtenir une carte d'occupation du sol.

---

1. À une résolution de N mètres, un pixel couvre une zone de  $(N \times N) m^2$

## Cadre collaboratif de segmentation et classification

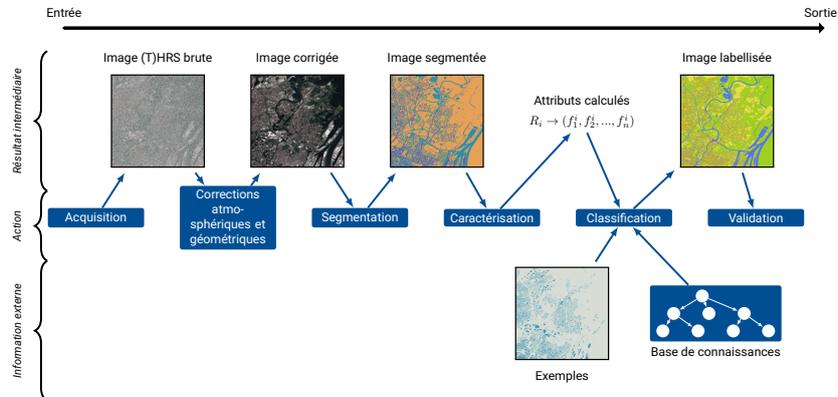


FIG. 1 – Schéma typique des approches OBIA

La qualité des résultats est évaluée au moyen de métriques prédéfinies ou directement par un expert.

De fait, l'étape de segmentation est cruciale pour obtenir une classification de qualité. En effet, de nombreuses études ont montré que les méthodes de classification avèrent d'autant plus efficaces que la segmentation induit une correspondance forte (un-à-un idéalement) entre les segments et les objets géographiques dans l'image (di Sciascio et al., 2013). Malheureusement, il n'existe pas d'algorithme de segmentation "idéal" permettant d'obtenir une telle correspondance dans toutes les situations.

Nous appuyons notre travail sur deux intuitions : (1) une amélioration de la segmentation devrait conduire naturellement à une amélioration de la classification ; et (2) les résultats de la classification peuvent s'avérer utiles pour guider la segmentation et ainsi améliorer sa qualité. Ainsi, nous proposons CoSC, un cadre collaboratif de segmentation et de classification permettant d'extraire les objets d'une classe thématique donnée. L'objectif du processus de collaboration, guidé par la qualité des données est d'améliorer la qualité de la classification via une amélioration de celle de la segmentation et réciproquement.

Le reste de cet article est structuré comme suit : la section 2 introduit le contexte et les travaux similaires qui ont inspiré notre proposition. La section 3 présente le cadre CoSC. La section 4 présente une étude expérimentale démontrant l'applicabilité de CoSC. Finalement, dans la section 5 nous concluons et donnons quelques perspectives de recherche.

## 2 Travaux connexes

La combinaison des tâches de segmentation et de classification a déjà été étudiée dans le contexte de la télédétection. Par exemple Lizarazo et Elsner (2011) propose un cadre de segmentation floue : les pixels sont classifiés de manière floue, pour créer des segments flous qui sont ensuite combinés en suivant un ensemble de règles logiques afin d'obtenir une image labellisée. Derivaux et al. (2010) propose un algorithme de segmentation supervisé, qui adapte les paramètres de l'algorithme *watershed* en fonction d'exemples fournis par un expert. Kurtz et al. (2012) développe une approche hiérarchique multi-résolution pour l'extraction d'ob-

jets complexes. L'approche accepte des données provenant de multiples capteurs, utilisant les images à basse résolution spatiale pour extraire des objets à un niveau sémantique assez général tels que les zones urbanisées versus les zones naturelles ou agricoles et les images à des résolutions de plus en plus grandes pour extraire des objets à un niveau sémantique de plus en plus spécifique comme des quartiers, puis des îlots urbain et enfin des bâtiments. Mahmoudi et al. (2013) propose un système multi-agent dans lequel chaque agent se spécialise dans l'extraction d'une classe donnée. Un agent particulier se charge de coordonner les autres agents et de résoudre les conflits éventuels. Récemment, Hofmanna et al. (2014) formalisent un cadre dit ABIA (Agent Based Image Analysis), où l'idée est d'instancier chaque segment sous la forme d'un agent qui peut se modifier lui même afin d'essayer d'améliorer et de modifier les règles de classification présentes dans une ontologie de domaine associée.

Notre travail s'inspire principalement du cadre proposé par Farmer (2009), qui essaie de segmenter des objets complexes en intégrant un contexte sémantique au processus de segmentation. Cette intégration se fait en utilisant un classifieur comme métrique de qualité pour l'algorithme de segmentation : ce classifieur, appris au préalable, permet de discriminer les objets d'une classe thématique donnée. Dans une première étape, une sur-segmentation est calculée. Ensuite, cette segmentation est modifiée en ajoutant ou en enlevant de manière itérative des segments de façon à maximiser la probabilité de classification de ceux-ci. L'utilisation de la classification pour guider la segmentation, permet d'injecter la sémantique implicitement codée dans le classifieur et enlève la contrainte d'homogénéité dans le processus de classification, permettant ainsi l'extraction d'objets complexes.

Néanmoins, ce cadre suppose que le nombre d'objets à extraire soit relativement faible et/ou que leur position puisse être facilement déterminée afin de filtrer les régions qui ne sont pas concernées c-à-d qui ne contiennent sûrement pas d'objets de la classe considérée. Généralement ces hypothèses ne sont pas satisfaites en télédétection. En effet, le nombre d'objets d'intérêt peut facilement aller de quelques dizaines (ex. écoles ou lycées), à plusieurs centaines (ex. bâtiments), ou au contraire, être très faible voire nul (ex. aéroport). De plus, les objets appartenant à une même classe peuvent présenter une variabilité forte sur leurs tailles ou leurs formes, ce qui rend difficile leur localisation même approximative. Nous proposons une généralisation de ce cadre, qui permet la modification des segments d'une manière plus flexible, et qui permet de considérer la totalité de l'image indépendamment de la taille, de la forme ou de la position des objets à extraire.

### 3 Proposition

Les paradigmes de segmentation et de classification ont des objectifs assez différents, mais ils sont étroitement liés dans le contexte de la télédétection. En effet, la segmentation partitionne l'image par rapport à des propriétés liées aux couleurs (réponses radiométriques) ; tandis que la classification partitionne l'espace des données (pixels de l'image) en se basant sur des connaissances qui peuvent être modélisées explicitement ou injectées de manière implicite sous la forme d'exemples.

Notre intuition dicte que des interactions entre ces deux approches devraient permettre une amélioration conjointe de leurs résultats, puisque la segmentation idéale est celle qui permet de mieux classifier l'image et une classification parfaite produit une correspondance de un-à-un entre les segments et les objets géographiques représentés dans l'image.

Des études ont montré l'intérêt de traiter une seule classe thématique à la fois (Musci et al., 2013). En effet, il s'avère plus simple d'instancier un algorithme de segmentation pour faire en sorte que les segments résultants correspondent à une classe thématique sans se soucier du reste. Par conséquent, la classification des objets de cette classe thématique est améliorée.

Ainsi, notre cadre collaboratif COSC est spécialisé dans l'extraction d'une seule classe thématique  $C_k$  choisie par l'expert. Nous supposons alors disposer :

- d'une segmentation initiale  $\mathcal{S} = \{R_i \mid 0 < i < N_R\}$  où  $N_R$  est le nombre de segments ; et chaque segment  $R_i$  est défini par  $R_i = \{(x_k^i, y_k^i) \mid 0 < k < M_i\}$  avec  $M_i$  le nombre de pixels dans  $R_i$  ;
- d'un classifieur un-contre-tous  $\mathcal{C}_{C_k}$  entraîné pour discriminer la classe  $C_k$ .

### 3.1 Définitions

Nous posons maintenant quelques définitions nécessaires pour décrire formellement le cadre proposé.

**Définition 1** Un segmenteur spécialisé  $S_C$  est un agent de segmentation capable d'évaluer et modifier localement un segment  $R$  donné.

**Définition 2** Un extracteur de classe  $C_{C_k}$  est un agent de classification capable de déterminer à partir de  $\mathcal{C}_{C_k}$ , la probabilité  $P_{C_k}(R)$  qu'un segment  $R \in \mathcal{S}$  appartienne à la classe  $C_k$ .

**Définition 3** Un agent de collaboration  $SC_{C_k}$  est un agent capable de gérer la collaboration entre un segmenteur spécialisé  $S_C$  et un extracteur de classe  $C_{C_k}$ .

**Définition 4** Un segment  $R \in C_k$  (resp.  $R \notin C_k$ ) ssi  $P_{C_k}(R) \geq T_\in$  (resp.  $P_{C_k}(R) \leq T_\notin$ ) avec  $T_\in > T_\notin \in [0, 1]$ . Ces deux seuils donnent lieu à une zone de rejet pour le classifieur (Chow, 1970).

**Définition 5** Un segment  $R$  tel que  $T_\notin < P_{C_k}(R) < T_\in$  est dit ambigu.

### 3.2 Le processus CoSC

Le processus collaboratif, réalisé par  $SC_{C_k}$ , consiste à échanger des informations entre un segmenteur spécialisé  $S_C$  et un extracteur de classe  $C_{C_k}$  :

1.  $S_C$  produit une segmentation initiale  $\mathcal{S}$  quelconque. Nos expériences montrent que lorsque la taille des segments est proche de la taille des objets de la classe  $C_k$  alors le processus converge plus rapidement et avec des meilleurs résultats.
2. Une étape de modifications locales est alternée avec une étape d'évaluation jusqu'à ce que la méthode converge :
  - (a) Dans l'étape de modification locale  $t$ ,  $C_{C_k}$  classe les segments de la segmentation  $\mathcal{S}_t$  selon leur probabilité d'appartenance  $P_C(R_i)$  et sélectionne un segment  $R_a$  suivant un critère donné (cf. ci-dessous) et le communique au segmenteur. Le segmenteur  $S_C$  évalue  $R_a$  de manière locale pour déterminer si  $R_a$  est sur-, sous-, ou bien segmenté ; il modifie alors  $R_a$  en conséquence pour essayer d'améliorer sa segmentation.

- (b) Dans l'étape d'évaluation, la segmentation modifiée  $\mathcal{S}_{t+1}$  est transmise à l'extracteur  $C_{C_k}$  qui la classe et l'évalue de façon non supervisée.
- (c) Si le processus a convergé alors FIN (la meilleure segmentation/classification a été trouvée) sinon, l'étape 2 est ré-itérée.

Dans les sous-sections suivantes nous présentons en détail ces différentes étapes.

### 3.2.1 Modifications locales

À chaque itération, un segment  $R_a$  est choisi par l'extracteur  $C_{C_k}$  pour être candidat à modification. Il est crucial de sélectionner un bon segment candidat, autrement dit, un segment dont la modification pourrait réellement améliorer la classification. Il paraît naturel de sélectionner le segment le plus ambigu, comme suit :

$$R_a = \arg \min_{R_i} |P_C(R_i) - T_{avg}| \quad (1)$$

où  $T_{avg}$ , est la valeur moyenne entre  $T_\in$  et  $T_\notin$  :  $T_{avg} = \frac{T_\in + T_\notin}{2}$ .

D'autres stratégies pourraient être mises en œuvre ; par exemple sélectionner un segment de manière aléatoire ou sélectionner un segment avec une probabilité très proche à  $T_\in$  ou  $T_\notin$  dont l'étude sera sujet d'une prochaine publication.

On définit un opérateur de modification locale  $\mathcal{O}$  (fusion de segments, suppression de segment, ...) comme une fonction  $\mathcal{O} : \mathfrak{D}_i \rightarrow \mathfrak{D}_i$  où  $\mathfrak{D}_i = R_i \cup \mathfrak{N}_{R_i}$  et  $\mathfrak{N}_{R_i}$  est l'ensemble de points appartenant aux segments dans le voisinage de  $R_i$  (segments adjacents).

Soient  $O_L$ ,  $U_L$  et  $W_L$  trois listes de tels opérateurs  $\mathcal{O}$ . Lors de l'étape de modification, le segment  $R_a$  est évalué. Suivant qu'il soit sur- (resp. sous, resp. bien) segmenté, l'ensemble des opérateurs  $\mathcal{O}$  dans la liste  $O_L$ , (resp.  $U_L$ , resp.  $W_L$ ) sont appliqués (cf. Algo. 1 et 2).

---

#### Algorithme 1 : ApplyModifications

---

**Data** : Segment :  $R_a$ , List of  $\mathcal{O} : L$

**Result** : Segment :  $R_m$

**begin**

```

    L.shuffle()
    while L.iterator.has_next() do
        R_m ← modify(R_a, L.iterator.next())
        if R_m ≠ R_a then
            return R_m
    return R_a

```

---

A titre d'exemple, dans l'étude présentée dans la section suivante,  $O_L$  contient un opérateur de fusion  $\mathcal{F}$  basé sur la distance euclidienne dans l'espace  $L * a * b$  (Chen et Wang, 2004) ;  $U_L$  contient un opérateur d'érosion morphologique  $\mathcal{E}$  ; et  $W_L$  contient  $\mathcal{F}$ ,  $\mathcal{E}$  ainsi qu'un opérateur de dilatation  $\mathcal{D}$ . Si la topologie du segment est changée par l'opérateur, la modification n'est pas prise en compte. Ainsi si  $R_a$  est :

- sur-segmenté,  $\mathcal{F}$  est appliqué ;
- sous-segmenté,  $\mathcal{E}$  est appliqué ;

---

**Algorithme 2 : LocalModification**

---

**Data** : Segment :  $R_a$   
**Result** : Segment :  $R_m$   
**begin**  
    **if** *oversegmentation*( $R_a$ ) **then**  
        |  $R_m \leftarrow \text{ApplyModifications}(R_a, O_L)$   
    **else if** *undersegmentation*( $R_a$ ) **then**  
        |  $R_m \leftarrow \text{ApplyModifications}(R_a, U_L)$   
    **else**  
        |  $R_m \leftarrow \text{ApplyModifications}(R_a, W_L)$   
    **return**  $R_m$

---

- bien segmenté,  $\mathcal{F}$ ,  $\mathcal{E}$  et  $\mathcal{D}$  sont appliqués dans un ordre aléatoire, le premier qui modifie effectivement le segment est conservé.

### 3.2.2 Convergence

La qualité de la classification est évaluée de façon non-supervisée pour ne pas dépendre d'une vérité terrain qui est souvent manquante, incertaine ou incomplète en télédétection. Nous supposons que le modèle de classification  $\mathcal{C}_k$  est correctement entraîné. Nous proposons d'évaluer les performances du classifieur  $\mathcal{C}_k$  par sa capacité à séparer les objets de la classe  $\mathcal{C}_k$  du reste. Autrement dit, il s'agit de réduire le nombre de segments ambigus. La fonction d'évaluation  $Q_{cs}$  est définie comme suit :

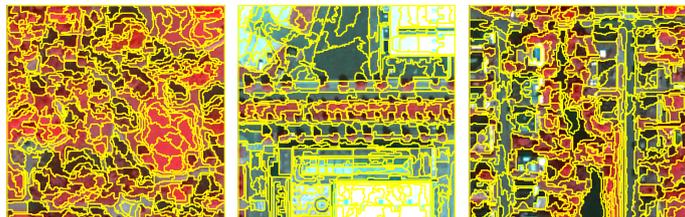
$$Q_{cs} = \frac{1}{N_R} \left( \sum_{i|P_{C_k}(R_i) > T_\epsilon} P_{C_k}(R_i) + \sum_{i|P_{C_k}(R_i) < T_\epsilon} 1 - P_{C_k}(R_i) \right) \quad (2)$$

où  $N_R$  est le nombre de segments dans la segmentation courante. Ainsi, plus la classe d'un segment  $R_i$  est certaine, plus  $R_i$  contribue au score. A contrario, les segments ambigus sont pénalisés de manière implicite puisqu'ils ne contribuent pas au score, mais ils sont pris en compte dans le facteur  $\frac{1}{N_R}$ . Le cas idéal où tous les segments sont classés avec 100% de certitude, nous donne  $Q_{cs} = 1.0$ . Dans le pire des cas où tous les segments sont ambigus, alors  $Q_{cs} = 0.0$ .

Pour éviter une convergence prématurée, nous acceptons un nombre  $D$  de modifications dégradantes en espérant sortir des minima locaux avec :

$$D = \frac{\mathcal{U} * N_R}{3} \quad (3)$$

où  $\mathcal{U}$  est le pourcentage de segments ambigus. Quand le processus atteint  $D$  étapes consécutives sans amélioration, on effectue un retour en arrière vers la meilleure solution trouvée. La convergence est atteinte lorsque l'on ne peut plus apporter d'améliorations à la solution. A noter que  $D$  diminue proportionnellement avec le nombre de segments ambigus. De fait, le processus converge plus rapidement au fur et à mesure que les segments sont améliorés.



(a) segmentation initiale du parc public (b) segmentation initiale des bâtiments industriels (c) segmentation initiale du quartier urbain

FIG. 2 – Segmentations initiales pour les trois imageries.

### 3.3 Données en sortie

À l'issue de chaque itération le résultat se compose de trois ensembles de segments différents :

- segments positivement classés (segments appartenant à  $\mathcal{C}_k$ ) ;
- segments négativement classés (segments n'appartenant pas à  $\mathcal{C}_k$ ) ; et
- segments ambigus.

## 4 Étude expérimentale

L'image étudiée est une image THRS Pleiades (©CNES) à 50cm,  $9211 \times 11275$  ( $10^8$  pixels) et avec 4 bandes spectrales : rouge, vert, bleu et proche infra-rouge. La classe thématique recherchée est celle de végétation.

Pour faciliter les calculs, nous avons découpé et traité l'image en 1620 imageries de  $256 \times 256$  pixels. Les résultats ont été reconstitués dans une seule image qui a été comparée à une vérité terrain existante. Cette vérité terrain a été générée en superposant une sur-segmentation de l'image avec des données vectorielles de référence sur la végétation. Comme les données vectorielles ne s'alignaient pas exactement avec les segments de l'image, nous avons associé à chacun d'eux un pourcentage de végétation formant ainsi une vérité terrain floue.

### 4.1 Instanciation

La métrique  $UOA_{L_2}$  (Troya-Galvis et al., 2015) a été employée pour évaluer la qualité de la segmentation. La fonction d'évaluation locale de  $UOA$  a été utilisée pour déterminer si les segments sont sur-, sous-, ou bien segmentés ; comme suit :

$$\phi_\delta(R_i) = \begin{cases} \text{sous-} & \text{si } H(R_i) > \delta \\ \text{sur-} & \text{si } H(R_i) \leq \delta \text{ et } \exists R_j \in \mathcal{N}(R_i), H(R_i \cup R_j) \leq \delta \\ \text{bien} & \text{sinon} \end{cases} \quad (4)$$

où  $H$  est un indice d'homogénéité et  $\delta$  est un seuil sur les valeurs de  $H$ . Dans cette expérience nous avons employé l'entropie (Zhang et al., 2003) ; après normalisation des valeurs de  $H$  par rapport à toute l'image,  $\delta = 0.75$  a été appris à partir d'exemples de segments correspondant à de la végétation.

Les segmentations initiales (Fig. 2) ont été effectuées avec un algorithme type mean-shift dont les paramètres ont été sélectionnés en évaluant 100 combinaisons différentes avec  $UOA_{L_2}$ .

Un modèle de régression linéaire à été appris en utilisant l'API de Weka (Hall et al., 2009). Le jeu d'entraînement est un sous-ensemble de la vérité terrain contenant des segments de végétation et de non-végétation choisis de manière aléatoire. Avec le pourcentage de végétation dans le segment comme valeur objectif de la régression. Les 32 caractéristiques employées pour décrire les segments incluent des attributs radiométriques telles que la moyenne ou l'écart type des bandes, ainsi que des attributs géométriques telles que l'aire, des indices de forme, entre autres. Les seuils de classification utilisés sont  $T_\epsilon = 0.9$  et  $T_\zeta = 0.1$ .

## 4.2 Résultats

Nous avons comparé CoSC à une méthode orientée pixel simple et à une méthode OBIA classique. La méthode basée pixel a consisté à associer à chaque pixel son indice NDVI (Rouse et al., 1974) qui est très utilisé en télédétection pour caractériser la végétation. L'image du NDVI a été normalisée entre  $[0, 1]$  pour que chaque valeur de pixel puisse être vue comme une probabilité. Pour la méthode OBIA classique, nous avons classé les segmentations initiales avec le même modèle de régression que nous utilisons dans CoSC.

### 4.2.1 En classification

Pour valider les résultats, nous avons calculé les métriques classiques : accuracy (Acc), Precision (Pr), Recall (Re), F-measure (Fm), et Cohen's kappa ( $\kappa$ ). Un seuil de 0.5 à été appliqué pour déterminer si un segment de la vérité terrain floue correspond ou non à de la végétation. Le tableau 1 montre les résultats de ces métriques pour les trois méthodes évaluées. Les seuils  $T_\epsilon = 0.9$  et  $T_\zeta = 0.1$  ont été employés pour définir la zone de rejet. Notons que les segments restant dans la zone de rejet (ambigus) ne sont pas pris en compte dans le calcul des métriques. Nous observons que le NDVI atteint une très haute accuracy mais le pourcentage de pixels ambigus est de 89%. L'approche OBIA classique atteint des performances acceptables pour Acc, Pr, Re, Fm et  $\kappa$  et réduit le pourcentage de pixels ambigus à 52%. CoSC atteint des résultats similaires à OBIA mais avec un moindre pourcentage de pixels ambigus (46%) cela montre que CoSC a réussi à réduire les ambiguïtés.

Nous avons décidé d'effectuer l'évaluation des résultats de manière floue également, étant donné que les résultats et la vérité terrain sont flous. À partir de la matrice d'erreur floue (Binaghi et al., 1999), nous avons calculé les métriques  $\widetilde{Acc}$ ,  $\widetilde{Pr}$ ,  $\widetilde{Re}$ , and  $\widetilde{Fm}$ . Ainsi, les calculs prennent en compte l'incertitude présente dans la vérité terrain pour obtenir une évaluation plus précise des résultats. Le tableau 2 montre les résultats de l'évaluation floue. Nous observons que le NDVI est globalement moins performant que les deux autres méthodes. Encore une fois, il n'y a pas de différence remarquable entre OBIA et CoSC en termes de classification, tous les deux ont atteint une performance acceptable.

### 4.2.2 En segmentation

Si nous observons de près les résultats en termes de segmentation, nous constatons qu'il y a des nettes différences. Les figures 4, 3, et 5 illustrent en détail les résultats de OBIA, NDVI,

Image	Acc	Pr	Re	Fm	$\kappa$	Am%	$Q_{cs}$
NDVI	<b>1.00</b>	<b>1.00</b>	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>	0.89	0.10
OBIA	0.93	0.95	0.95	0.95	0.83	0.52	0.48
CoSC	0.93	0.95	0.94	0.95	0.85	<b>0.46</b>	<b>0.53</b>

TAB. 1 – Métriques de qualité standard

Image	$\widetilde{Acc}$	$\widetilde{Pr}$	$\widetilde{Re}$	$\widetilde{Fm}$
NDVI	0.77	<b>0.79</b>	0.72	0.75
OBIA	0.81	0.75	<b>0.92</b>	<b>0.83</b>
CoSC	<b>0.82</b>	0.78	0.85	0.82

TAB. 2 – Métriques de qualité floues

et CoSC respectivement pour trois imageries différentes. La première ligne montre l'image des probabilités obtenue avec chaque méthode. La deuxième ligne montre les frontières des segments définis par les zones plates de l'image des probabilités, c'est-à-dire par les pixels adjacents ayant une même probabilité. Nous constatons que le NDVI permet de bien différencier les zones de végétation, mais l'image des probabilités est très bruitée : cela provient d'une segmentation fortement sur-segmentée. L'approche OBIA classique permet également de discriminer la végétation mais la segmentation associée est toujours sur-segmentée à des nombreux endroits. CoSC sépare nettement mieux les objets en donnant une plus haute probabilité aux régions de végétation et une très faible probabilité aux autres régions. Si nous regardons la segmentation associée, nous remarquons que celle-ci ne possède presque pas de sur- ou de sous segmentation. Ceci est très surprenant puisque même les objets qui n'appartiennent pas à la classe végétation sont maintenant correctement segmentés. On peut expliquer ceci par le fait que le processus prend en compte des critères d'homogénéité radiométriques pour choisir la façon dont les segments sont modifiés pendant le processus collaboratif. Le processus CoSC permet ainsi d'améliorer de manière globale la segmentation de toute l'image.

## 5 Conclusion

Dans cet article nous avons présenté CoSC, un cadre collaboratif de segmentation et classification. Il permet l'extraction des objets d'une classe thématique donnée grâce à l'échange d'information implicite entre ces deux paradigmes, améliorant ainsi simultanément les résultats. Nous avons présenté l'extraction de la végétation sur une grande image de la ville de Strasbourg. Cette étude expérimentale a permis de montrer l'applicabilité de CoSC. Les résultats montrent que CoSC permet d'obtenir des bons taux de classification en améliorant remarquablement la segmentation non seulement des objets d'intérêt mais de l'image entière. À court terme notre recherche se focalisera sur l'étude de nouvelles stratégies pour choisir le segment candidat et leurs influences sur le résultat final. CoSC est conçu pour l'extraction d'une seule classe thématique. À moyen terme nous travaillerons à mettre en place une méthode de collaboration entre plusieurs instances de CoSC pour effectuer l'interprétation thématique complète de l'image.

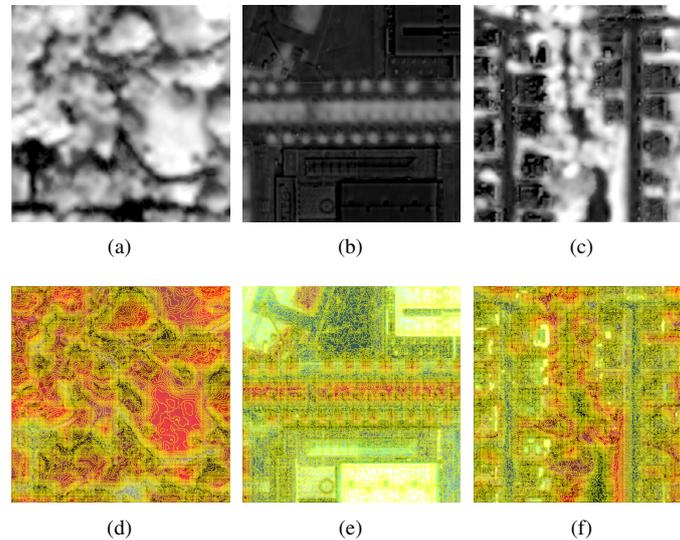


FIG. 3 – Vue détaillée des résultats obtenus avec le NDVI. La première colonne correspond à un parc public, la deuxième correspond à des bâtiments industriels et la troisième correspond à un quartier résidentiel. 3(a) à 3(c) montrent la probabilité que chaque pixel soit de la végétation ; le noir correspond à 0.0 et le blanc correspond à 1.0. 3(d) à 3(f) montrent les segmentations associées aux images de probabilité.

## Références

- Binaghi, Brivio, Ghezzi, et Rampini (1999). A fuzzy set-based accuracy assessment of soft classification. *Pattern Recognition Letters* 20(9), 935 – 948.
- Chen et Wang (2004). The use of visible color difference in the quantitative evaluation of color image segmentation. In *ICASSP. Proc.*, pp. 593–596.
- Chow (1970). On optimum recognition error and reject tradeoff. *Information Theory, IEEE Transactions on* 16(1), 41–46.
- Derivaux, Forestier, Wemmert, et Lefèvre (2010). Supervised image segmentation using watershed transform, fuzzy classification and evolutionary computation. *Pattern Recogn Lett* 31, 2364–2374.
- di Sciascio, Zanni-Merk, Wemmert, Marc-Zwecker, et de Beuvron (2013). Towards a semi-automatic semantic approach for satellite image analysis. *Procedia Computer Science* 22, 1388–1397.
- Farmer (2009). *Application of the Wrapper Framework for Robust Image Segmentation For Object Detection and Recognition*. INTECH Open Access Publisher.
- Hall, Frank, Holmes, Pfahringer, Reutemann, et Witten (2009). The weka data mining software : an update. *ACM SIGKDD explorations newsletter* 11(1), 10–18.
- Hofmann, Lettmayerb, Blaschkea, Belgiua, Wegenkittlb, Grafb, Lampoltshammera, et Andre-

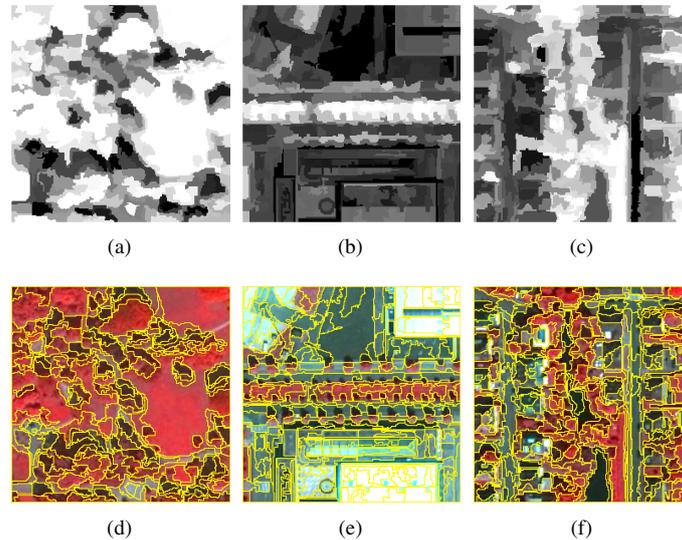


FIG. 4 – Vue détaillée des résultats obtenus avec OBIA classique. La première colonne correspond à un parc public, la deuxième correspond à des bâtiments industriels et la troisième correspond à un quartier résidentiel. 4(a) à 4(c) montrent la probabilité que chaque pixel soit de la végétation ; le noir correspond à 0.0 et le blanc correspond à 1.0. 4(d) à 4(f) montrent les segmentations associées aux images de probabilité.

- jchenkoa (2014). Abia - a conceptional framework for agent based image analysis. *South-Eastern European Journal of Earth Observation and Geomatics* 3(25), 125–129.
- Kurtz, Passat, Gançarski, et Puissant (2012). Extraction of complex patterns from multiresolution remote sensing images : A hierarchical top-down methodology. *Pattern Recognition* 45, 685–706.
- Lizarazo et Elsner (2011). Segmentation of remotely sensed imagery : moving from sharp objects to fuzzy regions. *Image Segmentation*.
- Mahmoudi, Samadzadegan, et Reinartz (2013). Object oriented image analysis based on multi-agent recognition system. *Computers & Geosciences* 54, 219–230.
- Musci, Feitosa, et Costa (2013). An object-based image analysis approach based on independent segmentations. In *Urban Remote Sensing Event (JURSE), 2013 Joint*, pp. 275–278.
- Pham, Yamaguchi, et Q. Bui (2011). A case study on the relation between city planning and urban growth using remote sensing and spatial metrics. *Landscape Urban Plan* 100, 223–230.
- Promper, Puissant, Malet, et Glade (2014). Analysis of land cover changes in the past and the future as contribution to landslide risk scenarios. *Applied Geography* 53(0), 11 – 19.
- Räsänen, Rusanen, Kuitunen, et Lensu (2013). What makes segmentation good ? a case study in boreal forest habitat mapping. *Int. J. Remote Sens.* 34, 8603–8627.
- Rouse, Haas, Schell, Deering, et Harlan (1974). *Monitoring the vernal advancement and re-*

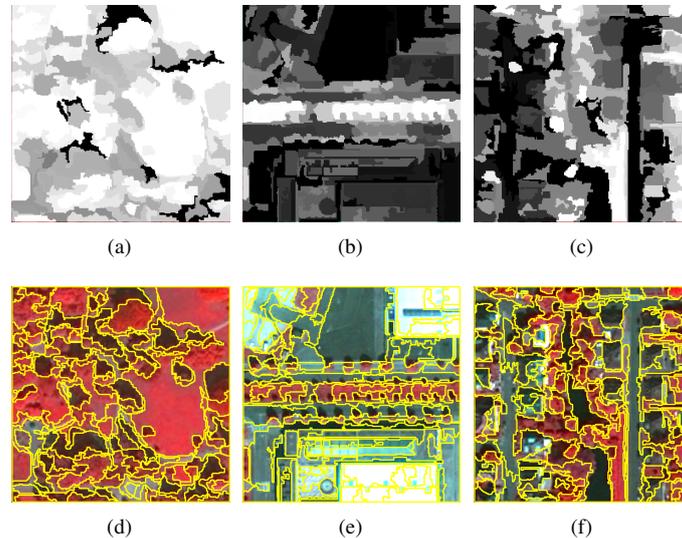


FIG. 5 – Vue détaillée des résultats obtenus par CoSC. La première colonne correspond à un parc public, la deuxième correspond à des bâtiments industriels et la troisième correspond à un quartier résidentiel. 5(a) à 5(c) montrent la probabilité que chaque pixel soit de la végétation ; le noir correspond à 0.0 et le blanc correspond à 1.0. 5(d) à 5(f) montrent les segmentations associées aux images de probabilité.

*trogradation (greenwave effect) of natural vegetation.* Texas A & M University, Remote Sensing Center.

Troya-Galvis, Gañarski, Passat, et Berti-Équille (2015). Unsupervised quantification of under and over segmentation for object based remote sensing image analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8(5), 1936–1945.

Zhang, Fritts, et Goldman (2003). An entropy-based objective evaluation method for image segmentation. In *Electronic Imaging 2004*, pp. 38–49.

## Summary

In this article we present CoSC, a collaborative framework for joint segmentation and classification. The framework is guided by and aware of the quality of each segment at every stage; it allows the consideration of both homogeneity based criteria as well as implicit semantic criteria to extract the objects belonging to a given thematic class. Our experiments show that CoSC manages to reach good classification results while remarkably improving the segmentation results.