

Le projet FOURIRE* : une approche méthodologique pour l'intégration de l'incertitude dans le processus de reconnaissance d'objets urbains

Stella MARC-ZWECKER

Caroline RUDOLF

Laboratoire ICube, équipe SDC, CNRS, Université de Strasbourg, France

stella@unistra.fr

Résumé

Dans cet article nous présentons les concepts développés dans le cadre du projet FOURIRE, dont l'objectif est la prise en compte systématique de l'incertitude dans le processus de reconnaissance semi-automatique d'objets urbains issus d'images satellitaires à très haute résolution. Nous considérons, non seulement l'imprécision inhérente aux données issues des capteurs du satellite, mais aussi l'incertitude liée à l'interprétation de l'image. L'imprécision des données est traitée au sein d'une ontologie qui met en œuvre un raisonnement flou. L'interprétation subjective de l'image est matérialisée par le concept de « vérité terrain floue ». Celle-ci sert de support à la définition d'une méthode générale, qui permet d'évaluer la pertinence de la classification floue des segments de l'image, effectuée par les règles de l'ontologie.*

Mots Clef

Ontologie, classification floue, vérité terrain floue, méthode d'évaluation, reconnaissance d'objets urbains, images satellitaires.

Abstract

In this paper we present the concepts that we have developed in the FOURIRE project, which aims to take into account uncertainty and imprecision in the whole process of semi-automatic recognition of urban objects from very high resolution satellite imagery. We consider, not only the imprecision which is inherent to data coming from the satellite sensors, but also the uncertainty associated with the interpretation of the image. The vagueness of data is treated within an ontology which implements a fuzzy reasoning. We introduce the concept of « fuzzy ground truth », which takes into account the subjectivity from image interpretation, and serves as a support for the definition of a general method, which evaluates the relevance of the fuzzy classification by ontology rules of image segments.*

Keywords

Ontology, fuzzy classification, fuzzy ground truth, evaluation method, urban object recognition, satellite image.

1 Introduction

Nos travaux dans le domaine de la représentation de connaissances, ont pour objectif de proposer un système basé sur des ontologies, qui permette de guider le processus de reconnaissance semi-automatique d'objets urbains dans des images satellitaires à très haute résolution (THR) [de Bertrand de Beuvron et al., 2013]. La prise en compte systématique de l'incertitude et de l'imprécision est le fil conducteur de cette étude. Le plan de l'article est le suivant : tout d'abord, dans la section suivante, nous situons notre approche dans le contexte des travaux existants, puis nous en exposons les objectifs. Ensuite, dans la troisième section, nous présentons les principes du prototype FOURIRE*, et les concepts développés (ontologies, raisonnement flou, vérité terrain floue). Puis nous introduisons, dans la quatrième section, une méthodologie générale permettant d'évaluer la pertinence de la classification floue, effectuée par les règles de l'ontologie. Finalement, nous présentons les premiers résultats expérimentaux qui découlent de l'application de cette méthodologie, avant de conclure sur l'intérêt et les perspectives de ce travail.

2 Contexte et objectifs

2.1 Etat de l'art

Dans la communauté de la télédétection, deux paradigmes de classification des images coexistent : les approches orientées pixel et orientées objet [Bhaskaran et al., 2010]. Nous considérons ici la deuxième catégorie, et plus précisément l'approche GEOBIA (Geographic Object-Based Image Analysis) [Hay and Castilla, 2008], où les méthodes de classification consistent à partitionner l'image en régions appelées « objets image », qui représentent les objets d'intérêt. [Blaschke, 2010] souligne que les approches orientées objets sont mieux adaptées à des images à haute résolution que les approches centrées sur les pixels, car les objets recherchés sont constitués de plusieurs pixels (alors que dans les images à basse résolution, un pixel contient plusieurs objets). L'approche GEOBIA repose sur une conceptualisation des objets recherchés, qui décrit leurs caractéristiques intrinsèques (forme, taille, texture, couleur, etc.) et contextuelles (orientation, distance, relations spa-

*Fuzzy Ontologies for URban Image REcognition

tiales d'adjacence ou d'inclusion, etc.), et permet donc une meilleure intégration des connaissances des experts. Il en résulte que l'utilisation des ontologies, qui sont des outils formels permettant de spécifier la conceptualisation d'un domaine de connaissances [Gruber, 1995], semble bien adaptée aux approches GEOBIA [Blaschke et al., 2014]. Ainsi, le développement d'ontologies pour modéliser les systèmes d'information géographiques (SIG) a fait l'objet de nombreux travaux [Fonseca et al., 2002]. Les ontologies doivent permettre de partager la conceptualisation d'un domaine au sein d'une communauté, et donc de décrire des connaissances consensuelles sous forme de taxonomies, comme par exemple le CORINE Land Cover. [Arvor et al., 2013] réalisent une synthèse de l'utilisation des ontologies dans le domaine de la télédétection pour les approches GEOBIA : bien que celles-ci aient traditionnellement pour objectif de permettre une meilleure communication entre les acteurs du domaine, les ontologies peuvent aussi être utilisées avec une visée applicative [Andres et al., 2012, Durand et al., 2007], afin de guider l'interprétation automatique de l'image. Nos travaux se situent dans cette optique, dans la lignée des travaux de [Forestier et al., 2012], qui proposent une approche permettant de faire le lien entre les concepts de haut niveau et les données numériques issues de l'image. Ce problème, connu sous le nom de fossé sémantique [Smeulders et al., 2000], constitue la principale difficulté à laquelle se confrontent les approches ontologiques classiques, car elles formalisent des concepts de haut niveau, sans pouvoir les relier aux données numériques qui caractérisent ces concepts au niveau physique. Par ailleurs, les experts décrivent souvent leur connaissance en langage naturel et de manière qualitative (par exemple un lac est une grande étendue d'eau, ou la texture d'une forêt est dense, etc.). Afin de pouvoir utiliser ces règles il faut lier les valeurs qualitatives à des valeurs quantitatives (problème de l'ancrage des symboles [Coradeschi and Saffiotti, 2003]). La logique floue est particulièrement bien adaptée à la représentation des concepts décrits en langage naturel, de façon vague ou imprécise [Bouchon-Meunier, 2007]. [Khalfi et al., 2015] proposent l'approche « F-Perceptory », basée sur une représentation UML (Unified Modeling Language), qui modélise l'incertitude et l'imprécision spatiale et temporelle des données au sein des systèmes d'information géographiques (SIG). En outre, plusieurs travaux intègrent des concepts flous dans les ontologies : [Stoilos et al., 2005, Bobillo and Straccia, 2011] ont respectivement défini un modèle formel pour les ontologies à concepts flous, et implémenté les plug-ins Fuzzy-OWL et Fuzzy-DL pour Protégé dans le contexte du web sémantique. Dans le cadre GEOBIA, [Sebari and He, 2013] implémentent une base de règles floues, permettant de reconnaître automatiquement des objets urbains extraits d'images satellitaires THR. Les travaux de [Hudelot et al., 2008, Vanegas et al., 2009] modélisent des relations spatiales floues dans des

ontologies, et ceux de [de Saint-Cyr and Prade, 2008, de Saint-Cyr et al., 2008] proposent une formalisation logique pour intégrer dans des ontologies des données spatiales imprécises en provenance de plusieurs sources. À notre connaissance, peu de travaux proposent des ontologies intégrant un raisonnement flou pour la reconnaissance d'images urbaines satellitaires [Belgiu et al., 2013, Zanni-Merk et al., 2015].

2.2 Objectifs et propositions

Dans le cadre du projet FOURIRE, nous poursuivons nos travaux sur le prototype que nous avons implémenté dans le cadre du projet ANR COCLICO (Collaboration, Classification, Incrémentalité, et Connaissances [Marc-Zwecker et al., 2014]). Deux types d'approches permettent de construire une segmentation « floue » :

- l'approche *orientée pixel*, que nous avons explorée dans le cadre du projet FOURIRE, et qui a consisté à utiliser la théorie de l'évidence de Dempster-Shafer ([Shafer et al., 1976]) pour construire des segments « flous » d'ombre et de végétation.
- l'approche *orientée objets*, qui a consisté à utiliser une segmentation réalisée par un algorithme standard, puis à définir des règles réalisant la classification floue des segments obtenus. C'est cette deuxième alternative qui a été retenue, car elle est plus conforme avec l'approche GEOBIA.

Ainsi, le prototype implémenté, réalise une sur-segmentation d'une image urbaine à très haute résolution. L'idée est de regrouper les segments adjacents appartenant *plus ou moins* à une même classe primaire (végétation, eau, sol nu, ombre, artificiel, etc.), dans l'objectif de reconstruire les objets d'intérêt (bâtiments, routes, parcs, piscines, lacs, etc.).

La prise en compte systémique de l'imprécision et de l'incertitude se fait à plusieurs niveaux de l'analyse :

- Tout d'abord, la classification des segments de l'image est considérée comme *floue*, i.e. que les segments appartiennent (avec des degrés d'appartenance compris entre 0 et 1) aux différentes classes primaires (par exemple à la végétation et à l'ombre avec des degrés respectifs de 0.6 et 0.7). Notons ici que la somme des degrés d'appartenance d'un segment aux différentes classes n'est pas forcément égale à 1 (il peut être inférieur ou supérieur). Ces degrés d'appartenance des segments aux classes sont calculés par les règles de l'ontologie. L'objectif est de permettre une meilleure souplesse pour la construction des objets recherchés. Par exemple un segment appartenant à la classe « Ombre » et n'appartenant pas à la classe « Végétation » (i.e. segment de type artificiel ou sol nu), pourra appartenir à la frontière d'un bâtiment.
- Ensuite, afin d'évaluer la pertinence de la classification floue obtenue, nous avons introduit le concept de « vérité terrain floue », qui permet d'interpréter l'image sans devoir prendre de décision *rigide* sur les contours des objets (en effet ceux-ci sont souvent imprécis, même sur une image

satellitaire à très haute résolution). Ces zones incertaines pourront donc être chevauchées par plusieurs classes.

- Finalement, nous proposons une méthodologie générale pour l'évaluation de la pertinence d'une classification floue, qui repose sur la définition d'une « vérité terrain floue ». Cette méthode est indépendante de la segmentation utilisée, ainsi que des règles de classification. Bien que notre expérimentation soit appliquée à une image satellitaire à très haute résolution, cette méthodologie est applicable à des images à plus basse résolution.

3 Présentation du prototype FOURIRE

Le fonctionnement du prototype FOURIRE est illustré dans la figure 1. On travaille sur des extraits de l'image en entrée, qui est une image urbaine à très haute résolution (cf. figure 1 étape b), segmentée selon l'algorithme « MeanShift » [Fukunaga and Hostetler, 1975] par l'intermédiaire de l'« Orfeo Tool Box » développée par le CNES¹ [Inglada and Christophe, 2009]. Cependant n'importe quel algorithme de segmentation peut être considéré, sous réserve que les segments obtenus soient « inclus » dans les objets d'intérêt. En effet, dans les approches GEOBIA, la segmentation de l'image est considérée comme une étape vers la recherche des objets et non comme une fin en soi [Blaschke et al., 2014].

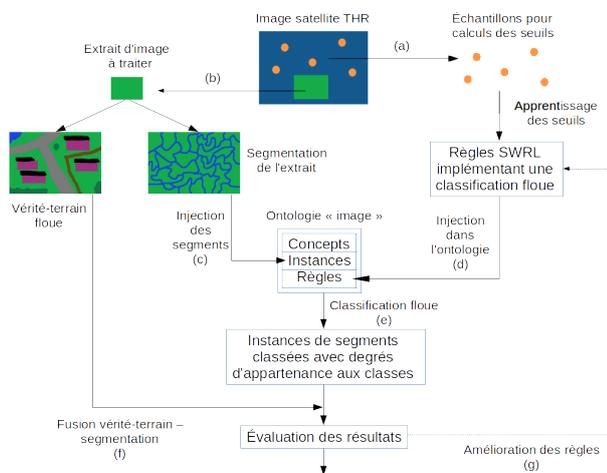


FIGURE 1 – Schéma fonctionnel du prototype FOURIRE

Les différentes étapes décrites dans la figure 1 sont présentées progressivement dans les sections suivantes.

3.1 Les ontologies

Nous avons implémenté deux ontologies :

- une ontologie du « domaine », qui a été définie d'après un dictionnaire d'objets urbains établi par des experts géographes [de Bertrand de Beuvron et al., 2013]. Les propriétés des objets urbains sont décrites qualitativement,

et l'objectif de notre prototype est d'utiliser les objets géographiques de l'ontologie du domaine pour guider la construction des objets image.

- une ontologie « image », qui contient des concepts à plusieurs niveaux d'abstraction [Marc-Zwecker 2014] :

- l'*image*, dont les propriétés sont des métadonnées (type de capteur satellite, géolocalisation, date, résolution, etc.)

- les *objets de l'image*, qui sont décrits par leurs caractéristiques (taille, forme, texture, couleur, etc.)

- les *segments de l'image*, qui sont décrits par leurs attributs : *label*, valeur moyenne des bandes spectrales, taille en pixels, et des indices calculés tels que le NDVI (indice de végétation normalisé), SAVI (indice de végétation ajusté au sol), NDWI (indice d'eau normalisé), etc. Remarquons que le *label* d'un segment permet de le relier à sa description dans le système d'information géographique QGIS (Quantum GIS), et ainsi de le visualiser sur l'image géo-référencée d'origine (cf. figures 4 et 5).

Les segments issus de l'extrait d'image sont injectés dans l'ontologie (cf. figure 1 étape c).

Les objets de l'image sont construits ultérieurement en regroupant les segments adjacents de même classe. Cette étape de construction des objets de l'image (par exemple bâtiments et routes) est en cours de développement. Les ontologies ont été implémentées en OWL2 (Ontology Web Language) sous l'éditeur Protégé².

3.2 Classification floue des segments dans l'ontologie

Sur des échantillons de segments de l'image d'entrée (cf. figure 1 étape a), nous avons effectué un apprentissage qui a permis de déterminer des seuils de valeurs pour des intervalles flous de type trapézoïdal [Bouchon-Meunier, 2007]. Ces intervalles permettent de déterminer, suivant les valeurs de différents paramètres significatifs (par exemple les valeurs moyennes des bandes spectrales), le degré d'appartenance (compris entre 0 et 1) du segment aux classes primaires. Bien que notre ontologie soit capable de déduire que les segments n'appartenant pas aux classes primaires inférées par les règles (i.e. Végétation, Ombre, Eau et Sol Nu) appartiennent à la classe « Artificiel » (qui englobe les bâtiments et les routes), l'objectif est ici de montrer la démarche méthodologique d'évaluation de la classification floue des segments. Aussi, dans le cadre de l'expérimentation, nous avons limité les classes étudiées à « Végétation » et « Ombre ». D'une part, ce choix est cohérent avec des études existantes qui privilégient la détection simultanée d'ombre et de végétation pour l'extraction de bâtiments [Ngo et al., 2014]. En effet, l'intérêt de la classe « Ombre » est d'aider à la reconstruction des bâtiments et à leur différenciation par rapport aux autres surfaces artificielles plates (routes, parkings, places, etc.). D'autre part, ce choix est adapté à l'extrait d'image sur lequel nous avons élaboré la *vérité terrain floue*, car il s'agit d'un environnement très

1. Centre National des Etudes Spatiales

2. développé par l'Université de Stanford, USA

urbain qui ne contient ni de l'eau, ni du sol nu (cf figure 6). Le raisonnement permettant d'implémenter les intervalles flous caractérisant les degrés d'appartenance des segments aux classes, est traduit sous forme de règles SWRL (Semantic Web Rule Language [Horrocks 2004]) d'après la méthode décrite dans [Fudholi et al., 2009]. Ces règles sont injectées dans l'ontologie « image » (cf. figure 1 étape *d*). Remarquons qu'un segment peut être classé par les règles de l'ontologie (cf. figure 1 étape *e*) comme appartenant à plusieurs classes. Cela se produit particulièrement pour la classe « Ombre », qui se « superpose » sur les autres classes. La figure 2 montre le segment de *label* 17574 classé dans l'ontologie (sous l'éditeur Protégé) à la fois comme « Ombre » (*Shadow_Segment*) et « Végétation » (*Vegetal_Segment_Moyen*).

La figure 3 montre le segment de *label* 9945 classé dans l'ontologie uniquement comme « Ombre » (*Shadow_Segment*). Nous revenons dans la section suivante sur l'analyse de la classification de ces segments.



FIGURE 2 – Description du segment de label 17574 dans l'ontologie sous l'éditeur Protégé



FIGURE 3 – Description du segment de label 9945 dans l'ontologie sous l'éditeur Protégé

3.3 Concept de vérité terrain floue

Le concept de « vérité terrain floue » existe déjà dans la littérature, mais s'applique essentiellement dans le contexte d'approches orientées pixel pour définir les degrés d'appartenance du pixel aux différentes classes [Benz et al., 2004]. Nous proposons dans notre approche *orientée objets*, une nouvelle définition du concept de « vérité terrain floue », qui est basée sur le paradigme du « jaune » et du « blanc » d'œuf, utilisé en raisonnement spatial qualitatif. Ce paradigme, connu sous le nom de « egg/yolk » [Cohn and Gotts, 1996], définit pour les objets une zone *sûre* (le jaune d'œuf) et une zone *incertaine* (le blanc d'œuf). La « vérité terrain floue » permet donc de représenter des objets avec des frontières imprécises.

Les segments classés dans l'ontologie avec leurs degrés d'appartenance par classe sont ensuite projetés sur la vérité terrain floue (fusion vérité terrain-segmentation sur la figure 1 étape *f*). Puis la méthode d'évaluation que nous exposons dans la section 4 est appliquée, *classe par classe*, afin de tester si les règles de classification floue permettent de tenir compte de l'imprécision :

- un segment dont l'intersection avec le « jaune d'œuf » d'une classe est majoritaire, doit avoir un degré d'appartenance *élevé* pour cette classe,
- un segment dont l'intersection avec le « blanc d'œuf » d'une classe est majoritaire, doit avoir un degré d'appartenance *moyen* pour cette classe,
- un segment dont l'intersection avec l'extérieur d'une classe est majoritaire, doit avoir un degré d'appartenance *faible* pour cette classe.

La figure 4 illustre sur QGIS (avec un contour jaune), le segment géoréférencé de *label* 17574, qui a été présenté dans l'ontologie sur la figure 2. Dans la table des attributs de QGIS, apparaissent les degrés d'appartenance qui ont été calculés dans l'ontologie pour ce segment : 0.61094683 (ce qui est considéré comme un degré d'appartenance *moyen*) pour la classe « Végétation » (colonne *veg*) et 0.82397 (ce qui est considéré comme un degré d'appartenance *élevé*) pour la classe « Ombre » (colonne *shd*). Ces degrés d'appartenance sont confrontés pour chaque classe *C*, à l'intersection du segment avec le *jaune*, *blanc*, et *extérieur* de la classe *C* sur la vérité terrain floue. Ici le segment de *label* 17574 est recouvert à 97% par le « jaune » de la classe « Végétation » (colonne *vegeJ*), ce qui induira un taux de *faux négatifs* lors de l'évaluation de la classification de ce segment (son degré d'appartenance à la classe « Végétation » aurait dû être plus élevé). Inversement, le segment est recouvert à 53% par le « blanc » de la classe « Ombre » (colonne *shdB*), ce qui induira un taux de *faux positifs* lors de l'évaluation de la classification de ce segment (son degré d'appartenance à la classe « Ombre » aurait dû être moins élevé).

La figure 5 illustre sur QGIS le segment géoréférencé de *label* 9945, qui a été présenté dans l'ontologie sur la figure 3. Remarquons qu'il s'agit d'un segment d'ombre qui se projette sur de l'« artificiel » (par exemple route), et non sur de la végétation. Ceci est cohérent avec les degrés d'appartenance à la classe « Végétation » (0.10207), et à la classe « Ombre » (0.7804). Ainsi les règles de classification permettent sur ces exemples de distinguer un segment d'ombre se superposant sur de la végétation d'un segment d'ombre se superposant sur de l'« artificiel ».

La figure 6 représente un extrait de l'image de référence THR Pleiades³ de la ville de Strasbourg, acquise en 2012, dont la résolution est 0.7m/pixel et la taille 9211x11275 pixels. Sur cet extrait, nous avons construit la *vérité terrain floue*, représentée sur la figure 7.

Sur la *vérité terrain floue*, les zones certaines (jaune d'œuf) et incertaines (blanc d'œuf), sont représentées respectivement par des teintes plus sombres et plus claires de la même couleur. Par exemple pour les toits des bâtiments, la couleur rose foncé correspond à une zone sûre, et le rose plus clair à une zone incertaine (frontières des bâtiments).

3. Pleiades : satellite de résolution inférieure à 1m en panchromatique (CNES)

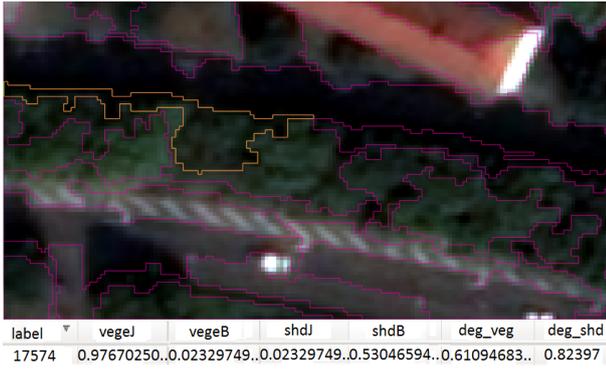


FIGURE 4 – Illustration d’un segment d’ombre qui se superpose sur de la végétation dans QGIS

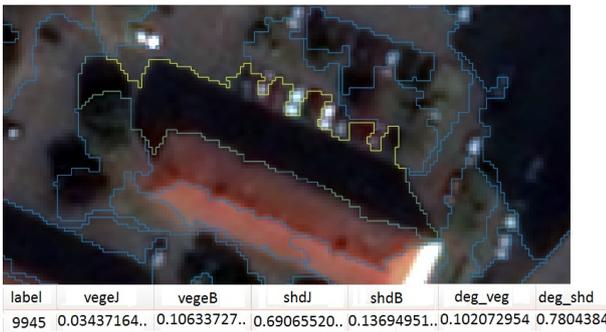


FIGURE 5 – Illustration d’un segment d’ombre qui se superpose sur de l’« artificiel » dans QGIS

4 Evaluation d’une classification floue sur vérité terrain floue

L’objectif de cette méthodologie est de fournir un cadre formel général pour l’évaluation d’une classification floue quelconque des segments d’une image (i.e. fournissant pour chaque segment son degré d’appartenance aux différentes classes considérées), par projection des segments sur une vérité terrain floue. Rappelons en effet que la classification se fait classe par classe, i.e. que le degré d’appartenance d’un segment est toujours relatif à une classe donnée. Nous définissons tout d’abord les variables que nous allons utiliser (l’indice f exprime une quantité floue, i.e. un *taux* compris entre 0 et 1) :

- $d(s, C_i)$: degré d’appartenance du segment s à la classe C_i ($0 \leq d(s, C_i) \leq 1$) calculé dans l’ontologie.
- $vp_f(s, C_i)$, $fp_f(s, C_i)$, $vn_f(s, C_i)$, $fn_f(s, C_i)$, correspondent respectivement au taux de vrais positifs, de faux positifs, de vrais négatifs et de faux négatifs, relatifs au segment s pour la classe C_i . Ces taux sont calculés par les formules d’évaluation que nous présentons ci-après.

Pour chaque segment s , l’invariant suivant est vérifié :

$$vp_f(s, C_i) + fp_f(s, C_i) + vn_f(s, C_i) + fn_f(s, C_i) = 1$$

Le pourcentage (ou taux) de recouvrement d’un segment s par une classe C_i est divisé en trois parties disjointes :



FIGURE 6 – Extrait d’image satellitaire de la cité de l’Ill (Strasbourg) ©LIVE



FIGURE 7 – Vérité terrain floue associée à l’extrait de la cité de l’Ill

- $P_{jaune}(s, C_i)$, qui représente le pourcentage du segment s qui est recouvert par la partie *sûre* de la classe C_i (« jaune d’œuf »),
- $P_{blanc}(s, C_i)$, qui représente le pourcentage du segment s qui est recouvert par la partie *incertaine* de la classe C_i (« blanc d’œuf »),
- $P_{ext}(s, C_i)$, qui représente le pourcentage du segment s qui est recouvert par une classe différente de C_i (*extérieur* de la classe C_i).

Le taux de recouvrement d’un segment s par une classe C_i vérifie l’invariant suivant :

$$P_{jaune}(s, C_i) + P_{blanc}(s, C_i) + P_{ext}(s, C_i) = 1$$

Nous proposons une formule générale d’évaluation qui repose sur la définition d’un seuil D ($0 \leq D \leq 1$), correspondant au degré que l’on considère comme étant le degré d’appartenance *moyen* caractérisant « au mieux » une zone de la vérité terrain floue. D varie en fonction de la zone considérée (jaune, blanc ou extérieur) :

- pour $P_{jaune}(s, C_i)$: $D = 1$
- pour $P_{blanc}(s, C_i)$: $0 < D < 1$
- pour $P_{ext}(s, C_i)$: $D = 0$

Pour les zones blanches, la valeur de D ($0 < D < 1$) doit être fixée arbitrairement. Cette valeur (par exemple $D = 0.5$) correspond au degré d’appartenance *moyen* d’un

segment à une zone blanche. Dans nos expérimentations (cf. section 5), nous avons fait varier la valeur de D . Notons que D est fixé pour l'image, mais qu'on pourrait le définir indépendamment pour chaque classe ($D(C_i)$).

Ainsi l'évaluation de la classification floue pour un segment s est optimale si le degré obtenu $d(s, C_i) = D$. En particulier :

- si $d(s, C_i) > D$, on considère que $d(s, C_i) - D$ correspond à un *surplus*, i.e à un taux de faux positifs.
- si $d(s, C_i) < D$, on considère que $D - d(s, C_i)$ correspond à une *carence*, i.e à un taux de faux négatifs.

Nous présentons ci-dessous les formules générales, qui permettent de calculer pour un segment s et une classe C_i , le taux de vrais positifs, de faux positifs, de vrais négatifs et de faux négatifs en fonction de son degré d'appartenance d à la classe C_i ($d = d(s, C_i)$) est calculé par les règles de l'ontologie), et des différents taux de recouvrement du segment par les zones « jaune », « blanche » et « extérieure » à la classe C_i (ceux-ci sont calculés lors de la projection du segment s sur la vérité terrain floue) :

- $vp_f(s, C_i) = \sum_j \min(d, D_j) \cdot P_j(s, C_i)$
- $fp_f(s, C_i) = \sum_j \max(0, d - D_j) \cdot P_j(s, C_i)$
- $vn_f(s, C_i) = \sum_j \min(1 - D_j, 1 - d) \cdot P_j(s, C_i)$
- $fn_f(s, C_i) = \sum_j \max(0, D_j - d) \cdot P_j(s, C_i)$

Où :

- l'indice $j \in \{jaune, blanc, ext\}$ ($\sum_j P_j(s, C_i) = 1$).
- D_j représente la valeur du degré D respectivement sur les zones « jaune », « blanc » et « extérieur » de la vérité terrain.

On en déduit le taux de vrais positifs, de faux positifs, de vrais négatifs et de faux négatifs sur toute l'image :

- $VP_f(C_i) = \sum_s vp_f(s, C_i) \cdot R(s)$
- $FP_f(C_i) = \sum_s fp_f(s, C_i) \cdot R(s)$
- $VN_f(C_i) = \sum_s vn_f(s, C_i) \cdot R(s)$
- $FN_f(C_i) = \sum_s fn_f(s, C_i) \cdot R(s)$

où $R(s)$ représente le ratio de la taille du segment s par rapport à la taille de l'image en nombre de pixels.

On peut maintenant calculer la précision floue $P_f(C_i)$, le rappel flou $R_f(C_i)$, et le F-mesure flou $FM_f(C_i)$, pour la classe C_i sur toute l'image, et ainsi évaluer la performance globale de la classification floue :

- $P_f(C_i) = VP_f(C_i) / (VP_f(C_i) + FP_f(C_i))$
- $R_f(C_i) = VN_f(C_i) / (VN_f(C_i) + FN_f(C_i))$
- $FM_f(C_i) = \frac{2 \cdot (P_f(C_i) \cdot R_f(C_i))}{(P_f(C_i) + R_f(C_i))}$

Nous présentons dans la section suivante quelques résultats de l'application expérimentale de ces formules.

5 Résultats expérimentaux

Nous avons réalisé une série de tests afin de comparer les classifications rigide et floue sur l'extrait d'image présenté sur la figure 6. Rappelons que :

- dans le cas d'une classification rigide, on définit un seuil de décision d_R tel que :
si $d(s, C_i) < d_R$ alors $d(s, C_i) = 0$ sinon $d(s, C_i) = 1$
- dans le cas d'une classification floue, la valeur de $d(s, C_i)$ n'est pas modifiée ($0 \leq d(s, C_i) \leq 1$).

Nous avons aussi testé l'évaluation des classifications rigide et floue sur des vérités terrain rigide et floue. Pour cela nous avons construit une vérité terrain rigide sur le même extrait d'image que la vérité terrain floue. Cependant les résultats sur vérité terrain rigide n'ont pas un grand intérêt dans le cadre de cette étude, car la classification floue devient triviale sur une vérité terrain rigide, la notion de « blanc d'œuf » disparaissant. Nous avons toutefois observé sur l'image testée, qu'avec une vérité terrain rigide, la classification rigide donne globalement de meilleurs résultats que la classification floue, sauf pour le rappel, qui est toujours meilleur avec la classification floue.

Nous nous concentrons ici sur la comparaison des classifications rigide et floue sur la vérité terrain floue illustrée dans la figure 7.

Bien que nous ayons testé plusieurs valeurs pour le seuil D caractérisant le degré *moyen* optimum ainsi que pour le seuil de décision d_R associé à la classification rigide, nous ne montrons ici que le cas où $D = 0.5$ (sur les zones blanches) et $d_R = 0.7$. En effet ce cas est représentatif de l'allure générale des résultats (sauf pour les seuils extrêmes).

La table 1 montre les résultats des évaluations pour tous les segments de l'image. Ceux-ci sont globalement meilleurs pour la classification rigide, particulièrement pour la végétation. Cela est dû au fait qu'il n'y a pas beaucoup de zones blanches sur la vérité terrain floue. En effet, l'image testée est à très haute résolution, et globalement peu de zones sont incertaines, surtout pour la végétation (il y a peu de segments contenant du « blanc » de végétation). Ainsi, la précision et le f-mesure pour l'ombre et la végétation sont meilleures avec une classification rigide, ce qui est cohérent, car prendre une décision rigide réduit le nombre de faux positifs quand le seuil de décision d_R est relativement élevé. Cependant, le rappel est bien meilleur en classification floue parce qu'on réduit le taux de faux négatifs.

Dans la table 2, on n'a évalué que les segments contenant au moins 40% de « blanc » au total (ombre et végétation confondues). Ce deuxième tableau indique que les résultats sont globalement meilleurs pour la classification floue, en particulier pour l'ombre, puisque toutes les mesures sont meilleures. Cela est prévisible car on a pris en compte les segments difficiles à classifier. Pour la végétation, le rappel et le f-mesure sont meilleurs en classification floue pour les mêmes raisons que pour l'ombre. Cependant, la précision reste bien meilleure avec une classification rigide, ce qui s'explique par le fait qu'il y a moins de segments « blancs » avec de la végétation.

On peut déduire de ces résultats, que la classification floue est d'autant plus intéressante qu'une classification rigide sur une vérité terrain floue, que la quantité de segments « blancs » est élevée. En effet, notre méthode pénalise l'évaluation des zones *certaines* et avantage l'évaluation des zones *incertaines* dans le cas d'une classification floue.

TABLE 1 – Résultats sur toute l'image avec $D = 0.5$ et $d_R = 0.7$

Classification	Végétation			Ombre		
	Précision	Rappel	f-measure	Précision	Rappel	f-measure
Floue	0.59	0.68	0.63	0.40	0.80	0.54
Rigide	0.94	0.62	0.74	0.64	0.59	0.61

TABLE 2 – Résultats sur les segments majoritairement blancs avec $D = 0.5$ et $d_R = 0.7$

Classification	Végétation			Ombre		
	Précision	Rappel	f-measure	Précision	Rappel	f-measure
Floue	0.46	0.40	0.43	0.63	0.85	0.72
Rigide	0.90	0.18	0.30	0.59	0.58	0.58

6 Conclusion et perspectives

Dans cet article, nous avons présenté les principes du projet FOURIRE, qui vise à prendre en compte l'incertitude dès le stade de classification des segments de l'image par les règles de l'ontologie. Nous avons introduit le concept de *vérité terrain floue*, basé sur le paradigme du « egg/yolk », et avons défini une méthodologie générale pour l'évaluation d'une classification floue des segments de l'image. Les résultats préliminaires sur l'évaluation de la classification floue montrent que l'intérêt de cette approche est étroitement lié à la quantité de zones incertaines dans l'image. Les expérimentations que nous avons conduites ici portent sur les classes « Végétation » et « Ombre ». Il serait intéressant de vérifier, qu'à l'instar des exemples choisis, les règles de classification permettent dans le cas général de distinguer les segments d'ombre qui se superposent sur de la végétation, de ceux qui se superposent sur de l'« artificiel ». Ce résultat pourrait faciliter l'étape de reconnaissance des bâtiments et des routes.

Afin de compléter cette analyse, nous élargissons actuellement nos tests, en choisissant des extraits d'image qui contiennent, d'une part, les classes « Eau » et « Sol nu » (décrites par les règles de l'ontologie), et d'autre part, davantage de zones incertaines. Pour satisfaire ce dernier point, nous avons sélectionné une image urbaine SPOT 7 à plus basse résolution que l'image Pléiades traitée ici. Nous sommes aussi en train de développer de nouvelles règles permettant de détecter les classes « Bâtiment » et « Route ». Ces règles exploitent, au moyen d'intervalles flous, des indices de formes et de couleurs caractérisant les objets de l'image, afin d'en permettre une reconstruction plus souple.

Il serait également intéressant d'élargir l'étude de l'incertitude et de l'imprécision en considérant des théories alternatives à la logique floue, comme par exemple la théorie de l'évidence de Dempster-Shafer pour réaliser la classification floue des segments, ou la théorie des ensembles approximatifs (« rough sets ») comme alternative à la théorie du « egg/yolk » pour la modélisation de la vérité terrain

floue ([Beaubouef et al., 2007]).

Enfin, les objets image construits dans l'ontologie constituent un socle pour l'intégration d'un raisonnement de plus haut niveau. En particulier, un raisonnement temporel sur des séquences d'images, permettra par exemple, d'analyser l'urbanisation d'une zone.

Remerciements

Nous remercions le laboratoire ICube qui a financé le projet FOURIRE, ainsi que Vincent Mazet, Agnès Braud, François de Bertrand de Beuvron, et Alexandre Corizzi pour leur participation au projet. Ce travail a été soutenu par le projet ANR Coclico (Contrat ANR-12-MN-0001).

Références

- [Andres et al., 2012] Andres, S., Arvor, D., and Pierkot, C. (2012). Towards an ontological approach for classifying remote sensing images. In *Eighth International Conference on Signal Image Technology and Internet Based Systems (SITIS)*, pages 825–832. IEEE.
- [Arvor et al., 2013] Arvor, D., Durieux, L., Andrés, S., and Laporte, M.-A. (2013). Advances in geographic object-based image analysis with ontologies : a review of main contributions and limitations from a remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82 :125–137.
- [Beaubouef et al., 2007] Beaubouef, T., Petry, F. E., and Ladner, R. (2007). Spatial data methods and vague regions : A rough set approach. *Applied Soft Computing*, 7(1) :425–440.
- [Belgiu et al., 2013] Belgiu, M., Lampoltshammer, T. J., Hofer, B., et al. (2013). *An extension of an ontology-based land cover designation approach for fuzzy rules*, volume 2013. Verlag der Österreichischen Akademie der Wissenschaften.
- [Benz et al., 2004] Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., and Heynen, M. (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for gis-ready information. *ISPRS Journal of photogrammetry and remote sensing*, 58(3) :239–258.
- [Bhaskaran et al., 2010] Bhaskaran, S., Paramananda, S., and Ramnarayan, M. (2010). Per-pixel and object-oriented clas-

- sification methods for mapping urban features using ikonos satellite data. *Applied Geography*, 30(4) :650–665.
- [Blaschke, 2010] Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1) :2–16.
- [Blaschke et al., 2014] Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Feitosa, R. Q., van der Meer, F., van der Werff, H., van Coillie, F., et al. (2014). Geographic object-based image analysis—towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87 :180–191.
- [Bobillo and Straccia, 2011] Bobillo, F. and Straccia, U. (2011). Fuzzy ontology representation using owl 2. *International Journal of Approximate Reasoning*, 52(7) :1073–1094.
- [Bouchon-Meunier, 2007] Bouchon-Meunier, B. (2007). *La logique floue : « Que sais-je ? »*. Number 2702. Presses universitaires de France.
- [Cohn and Gotts, 1996] Cohn, A. G. and Gotts, N. M. (1996). The egg-yolk representation of regions with indeterminate boundaries. *Geographic objects with indeterminate boundaries*, 2 :171–187.
- [Coradeschi and Saffiotti, 2003] Coradeschi, S. and Saffiotti, A. (2003). An introduction to the anchoring problem. *Robotics and Autonomous Systems*, 43(2) :85–96.
- [de Bertrand de Beuvron et al., 2013] de Bertrand de Beuvron, F., Marc-Zwecker, S., Puissant, A., and Zanni-Merk, C. (2013). From expert knowledge to formal ontologies for semantic interpretation of the urban environment from satellite images. *International Journal of Knowledge-Based and Intelligent Engineering Systems*, 17(1) :55–65.
- [de Saint-Cyr et al., 2008] de Saint-Cyr, F. D., Jeansoulin, R., and Prade, H. (2008). Fusing uncertain structured spatial information. In *Scalable Uncertainty Management*, pages 174–188. Springer.
- [de Saint-Cyr and Prade, 2008] de Saint-Cyr, F. D. and Prade, H. (2008). Logical handling of uncertain, ontology-based, spatial information. *Fuzzy Sets and Systems*, 159(12) :1515–1534.
- [Durand et al., 2007] Durand, N., Derivaux, S., Forestier, G., Wemmert, C., Gançarski, P., Boussaid, O., and Puissant, A. (2007). Ontology-based object recognition for remote sensing image interpretation. In *19th IEEE International Conference on Tools with Artificial Intelligence (ICTAI 2007)*, volume 1, pages 472–479. IEEE.
- [Fonseca et al., 2002] Fonseca, F. T., Egenhofer, M. J., Agouris, P., and Câmara, G. (2002). Using ontologies for integrated geographic information systems. *Transactions in GIS*, 6(3) :231–257.
- [Forestier et al., 2012] Forestier, G., Puissant, A., Wemmert, C., and Gançarski, P. (2012). Knowledge-based region labeling for remote sensing image interpretation. *Computers, Environment and Urban Systems*, 36(5) :470–480.
- [Fudholi et al., 2009] Fudholi, D. H., Maneerat, N., Varakulsiripunth, R., and Kato, Y. (2009). Application of protégé, swrl and sqwrl in fuzzy ontology-based menu recommendation. In *International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS 2009)*, pages 631–634. IEEE.
- [Fukunaga and Hostetler, 1975] Fukunaga, K. and Hostetler, L. D. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *Information Theory, IEEE Transactions on*, 21(1) :32–40.
- [Gruber, 1995] Gruber, T. R. (1995). Toward principles for the design of ontologies used for knowledge sharing? *International journal of human-computer studies*, 43(5) :907–928.
- [Hay and Castilla, 2008] Hay, G. J. and Castilla, G. (2008). Geographic object-based image analysis (geobia) : A new name for a new discipline. In *Object-based image analysis*, pages 75–89. Springer.
- [Hudelot et al., 2008] Hudelot, C., Atif, J., and Bloch, I. (2008). Fuzzy spatial relation ontology for image interpretation. *Fuzzy Sets and Systems*, 159(15) :1929–1951.
- [Inglada and Christophe, 2009] Inglada, J. and Christophe, E. (2009). The orfeo toolbox remote sensing image processing software. In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2009)*, pages 733–736.
- [Khalfi et al., 2015] Khalfi, B., de Runz, C., Faiza, S., and Akdag, H. (2015). Improvement of the f-perceptory approach through management of fuzzy complex geographic objects. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1 :235–241.
- [Marc-Zwecker et al., 2014] Marc-Zwecker, S., Asnour, K., and Wemmert, C. (2014). A fuzzy-rule based ontology for urban object recognition. In *6th International Conference on Knowledge Engineering and Ontology Development (KEOD 2014)*, pages 153–160.
- [Ngo et al., 2014] Ngo, T.-T., Collet, C., and Mazet, V. (2014). Détection simultanée de l’ombre et la végétation sur des images aériennes couleur en haute résolution. In *Reconnaissance de Formes et Intelligence Artificielle (RFIA 2014)*.
- [Sebari and He, 2013] Sebari, I. and He, D.-C. (2013). Automatic fuzzy object-based analysis of vhsr images for urban objects extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 79 :171–184.
- [Shafer et al., 1976] Shafer, G. et al. (1976). *A mathematical theory of evidence*, volume 1. Princeton university press Princeton.
- [Smeulders et al., 2000] Smeulders, A. W., Worring, M., Santini, S., Gupta, A., and Jain, R. (2000). Content-based image retrieval at the end of the early years. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(12) :1349–1380.
- [Stoilos et al., 2005] Stoilos, G., Stamou, G. B., Tzouvaras, V., Pan, J. Z., and Horrocks, I. (2005). Fuzzy owl : Uncertainty and the semantic web. In *OWL : Experiences and Directions, OWLED 2005*.
- [Vanegas et al., 2009] Vanegas, M. C., Bloch, I., and Inglada, J. (2009). Fuzzy spatial relations for high resolution remote sensing image analysis : The case of “to go across”. In *Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009*, volume 4, pages IV–773. IEEE.
- [Zanni-Merk et al., 2015] Zanni-Merk, C., Marc-Zwecker, S., Wemmert, C., and de Beuvron, F. d. B. (2015). A layered architecture for a fuzzy semantic approach for satellite image analysis. *International Journal of Knowledge and Systems Science (IJKSS)*, 6(2) :31–56.