

DÉLIMITATION DES PARCELLES AGRICOLES PAR CLASSIFICATION D'IMAGES PLÉIADES

Nesrine Chehata^{1,2}, Karim Ghariani³, Arnaud Le Bris⁴, Philippe Lagacherie⁵

1 : Bordeaux INP, G&E, EA 4592, Talence, France
nesrine.chehata@ensegid.fr

2 : IRD/UMR LISAH El Menzah 4, Tunis, Tunisia

3 : INSAT (Institut National des Sciences Appliquées et de Technologies), Tunis, Tunisia

4 : Université Paris-Est, IGN/SR, MATIS, Saint Mandé, France

5 : INRA Laboratoire LISAH, UMR 1221 Montpellier, France

Résumé

Les pratiques et les arrangements spatiaux des parcelles agricoles ont un fort impact sur les flux d'eau dans les paysages cultivés. Afin de surveiller les paysages à grande échelle, il y a un fort besoin de délimitation automatique ou semi-automatique des parcelles agricoles. Cet article montre la contribution des images satellitaires à très haute résolution spatiales, telles que Pléiades, pour délimiter le parcellaire agricole de manière automatique. Une approche originale utilisant une classification binaire supervisée des limites parcellaires est proposée. Une approche d'apprentissage actif est mise en oeuvre afin d'adapter le modèle de classifieur au contexte local permettant ainsi la délimitation parcellaire à grande échelle. Le classifieur des Forêts Aléatoires est utilisé pour la classification et la sélection des attributs. Le concept de marge non supervisée est utilisé comme mesure d'incertitude dans l'algorithme d'apprentissage actif. En outre, un étiquetage automatique des pixels incertains est proposé en utilisant une approche hybride combinant une approche région et le concept de marge. Des résultats satisfaisants sont obtenus sur une image Pléiades. Différentes stratégies d'apprentissage sont comparées et discutées. Pour un cas d'étude opérationnel, un modèle global ou bien un modèle simple enrichi peuvent être utilisés en fonction des données de terrain disponibles.

Mots clés : Classification, apprentissage actif, segmentation, parcelles agricoles, très haute résolution spatiale, Pléiades

Abstract

Agricultural practices and spatial arrangements of fields have a strong impact on water flows in cultivated landscapes. In order to monitor landscapes at a large scale, there is a strong need for automatic or semi-automatic field delineation. This paper shows the contribution of very high resolution satellite imagery, such as Pléiades imagery, for delineating agricultural fields in an automatic way. This study focuses on agricultural field delineation using a supervised binary classification of field boundaries. Active learning approach is proposed to adapt the classifier model to the local context allowing thus parcel delineation at a large scale. Random forest (RF) classifier is used for classification and feature selection. The unsupervised margin concept is used as uncertainty measure in the active learning algorithm. Besides, automatic labelling of uncertain pixels is proposed using a hybrid approach that combines a region-based approach and margin concept. Satisfying results are obtained on a Pléiades image. Different learning strategies are compared and discussed. For an operational case study, either a global model or an enriched simple model can be used depending on available ground truth.

Keywords : Classification, active learning, segmentation, agricultural fields, very high spatial resolution, Pléiades

1. Introduction

Les activités agricoles produisent une série d'éléments anthropiques (états de surface des sols, limites parcellaires, fossés, ...) qui exercent un impact majeur sur le fonctionnement hydrologique des paysages en modifiant les propriétés hydrodynamiques des sols et en introduisant des discontinuités hydrologiques modifiant les chemins de l'eau. Les arrangements spatiaux et la connectivité des champs cultivés ont un fort impact sur le ruissellement et l'érosion du sol à l'échelles du bas-

sin versant mais également à l'échelle du paysage (Colin et al., 2012). Dans la perspective de diagnostiquer et de maîtriser ces impacts, il est intéressant de détecter, de façon automatique et à grande échelle, les champs cultivés dans le but de cartographier les types de culture, de suivre les états de surface, de créer ou de mettre à jour une base de données de parcellaire. Pour répondre à ces enjeux, la télédétection à très haute résolution spatiale apparaît comme un outil adapté à l'analyse et la cartographie à grande échelle des éléments anthropiques des paysages cultivés.

Notre objectif est de détecter automatiquement les limites des parcelles à l'aide d'images satellitaires à très haute résolution (THR). Le problème est difficile en raison d'une forte variabilité des cultures agricoles d'une part mais aussi de la variabilité de la nature des limites parcellaires d'autre part. En pratique, certaines limites peuvent être délimitées par des digues, des levées de terre ou différentes végétations. Une autre difficulté réside dans la forte variabilité intra-parcelle qui rend difficile la segmentation d'une parcelle en tant qu'une seule unité.

Dans la littérature, peu de travaux existent dans la communauté de la télédétection, sur la délimitation automatique des parcelles agricoles. Nous avons donc élargi notre état de l'art aux techniques de détection d'objets utilisées en traitement d'images. Ces méthodes peuvent être regroupées en trois approches : 1) par régions 2) par contours et 3) par classification.

L'approche par régions est basée sur des techniques de segmentation orientées objet qui ont connu un fort essor dans les années 2000 avec l'arrivée des images satellitaires THR (Blaschke, 2010). Généralement, les régions sémantiquement significatives apparaissent à différentes échelles d'analyse ; on retrouve par conséquent différentes analyses hiérarchiques pour la segmentation de parcelles agricoles ou bien en milieu forestier (Benz et al. (2004); Trias-Sanz et al. (2008)). La plupart de ces travaux utilisent le logiciel eCognition (Baatz and Schäpe, 2000; Mallinis et al., 2008). Cependant, les principales difficultés qui se posent dans cette approche sont la forte variabilité de la nature des limites parcellaires et la forte variabilité intra-parcellaire.

La deuxième famille d'approches consiste à considérer les limites parcellaires comme des linéaires. Elle est basée sur la détection de contours en utilisant le gradient de l'image. Pour notre application, ces méthodes renvoient une surdétection des contours à cause des parcelles cultivées ou labourées.

La troisième approche consiste à détecter les contours par classification supervisée en réalisant l'apprentissage d'un modèle de contour i.e de limite parcellaire. Des descripteurs locaux de texture et de couleur sont calculés. L'algorithme BEL (Boosted Edge Learning) (Arbelaez et al., 2011) essaie d'entraîner un classifieur de contours par des arbres de décision. Il a été appliqué avec succès aux images naturelles et pourrait être intéressant pour la détection des limites de la parcelle. Dans notre contexte, cette méthode présente deux avantages ; d'une part la phase d'apprentissage permettra de prendre en compte la variabilité des limites parcellaires et d'autre part c'est une approche par contours qui sera donc plus robuste aux variabilités intra-parcelles. Son inconvénient est qu'elle nécessite une étape d'apprentissage. Pour notre étude, on retiendra cette dernière approche.

Notre objectif est de détecter les limites parcellaires en utilisant une classification binaire supervisée (*limite* Vs. *Non-limite*). Les limites parcellaires peuvent présen-

ter une grande variabilité qui est souvent mal représentée dans les ensembles d'apprentissage. Les techniques d'apprentissage actif (AL Active Learning) (Tuia et al., 2011b) semblent être appropriées pour résoudre ce problème, en enrichissant progressivement les données d'apprentissage permettant ainsi d'adapter le modèle du classifieur localement à différents types de limites parcellaires.

Dans cette étude, deux questions principales se posent : 1) quels sont les descripteurs d'images les plus appropriés pour la délimitation des parcelles agricoles ? 2) Comment assurer une bonne classification à grande échelle prenant en compte la variabilité des limites ?

Une approche hybride est proposée combinant une approche basée région et les techniques d'apprentissage actif. Le classifieur par forêts aléatoires (ou encore Random Forests RFTM) est utilisé pour la classification et la sélection des meilleurs attributs. Le concept de marge d'ensemble non supervisée est utilisé comme mesure d'incertitude du classifieur pour sélectionner les échantillons les plus incertains et donc les plus informatifs pour l'apprentissage. Les résultats sont présentés sur une image Pléiades THR, acquise pendant la période des labours. La section 2 présentera le site d'étude et les données disponibles. La section 3 présentera les attributs testés et l'approche proposée. Les résultats seront présentés et discutés dans la section 4.

2. Site et données

Le site d'étude est situé au nord-est de la Tunisie (Région du Cap Bon), dans le bassin versant du Lebna (~ 210km²). 10 lots de parcelles adjacentes ont été considérés, composés au total de 70 parcelles agricoles. La Figure 1 montre les différents lots considérés. La résolution spatiale des images Pléiades est de 0,7m ré-échantillonnée à 0,5m en panchromatique (Pan) et à 2m en multispectral (MS). En mode MS, quatre bandes spectrales sont disponibles (bleu, vert, rouge et proche Infra-rouge).

Les limites parcellaires de référence ont été saisies par photo-interprétation sur l'image panchromatique et validées sur le terrain. Enfin, pour être robuste aux erreurs de géoréférencement, les limites ont été dilatées par un élément structurant de taille 3×3 (Figure 7e).

3. Méthodologie

3.1. Les forêts aléatoires

Les Forêts Aléatoires (Random Forests TM) ou encore RFTM) sont constituées d'un ensemble de classifieurs supervisés implémentés sous la forme d'arbres de décision. L'approche consiste à générer des sous ensembles aléatoires de données d'apprentissage pour chaque arbre (type *bagging*) (Breiman, 2001). A partir de

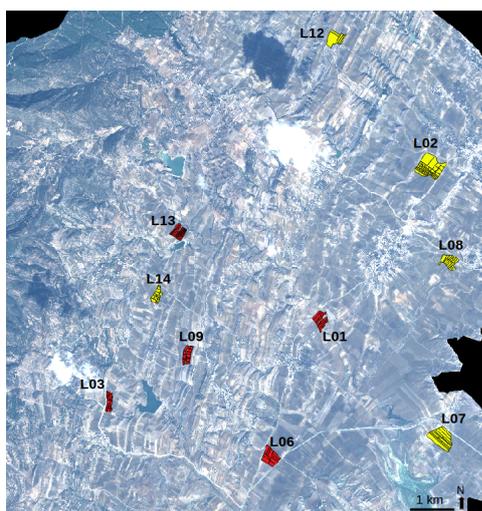


FIGURE 1 : Image Pléiades MS à 2m sur une partie du bassin versant du Lebna, Tunisie. Les lots ayant servi pour l'apprentissage et le test sont illustrés en jaune et rouge, respectivement. © CNES (2013), distribution Airbus DS / Spot Image.

chaque échantillon, un arbre de décision CART (Classification And Regression Trees) est construit et uniquement un sous ensemble aléatoire de M attributs est utilisé pour la division de chaque noeud. Pour une instance, chaque arbre renvoie un vote unitaire. Le label final est obtenu par vote majoritaire de tous les arbres. Le paramètre M est souvent fixé à $M = \sqrt{N}$ où N est le nombre de variables.

Pour l'apprentissage de chaque arbre, 2/3 des données sont tirées aléatoirement pour construire l'arbre. Le tiers des données restant constitue l'ensemble *out-of-bag* (OOB). Ces données permettent d'avoir une estimation non biaisée du taux d'erreur en généralisation sans avoir recours à un échantillon test supplémentaire ou à une validation croisée.

Le classifieur RF est peu sensible au bruit et aux données erronées. Il peut être utilisé pour la classification de données de grande dimension.

3.1.1. Importance des variables

À partir des arbres construits, l'importance d'une variable m peut être mesurée en permutant aléatoirement les valeurs de cette variable. On mesure alors, sur les données OOB, la différence de précision de classification après et avant permutation. Une augmentation de l'erreur OOB indique l'importance de la variable m . Cette mesure sera utilisée pour évaluer l'importance des variables choisies en entrée.

3.1.2. Marge non supervisée

Pour la classification binaire, une marge non supervisée est proposée (Guo et al., 2011). Elle correspond à la différence des pourcentages de votes pour la classe *Limite* et la classe *Non-limite*. On suppose que les instances d'apprentissage sont des paires (x_i, y_j) où x_i est

une instance et $y_j \in \{1, -1\}$ son label, 1 et -1 correspondent aux classes *limite* et *non-limite* respectivement. La marge m_i de l'instance x_i est calculée comme suit :

$$m_i = \text{margin}(x_i) = \frac{v_{(i,1)} - v_{(i,-1)}}{\sum_{y_j \in \{1, -1\}} v_{(i,y_j)}} \quad (1)$$

avec $v_{(i,y_j)}$ le nombre de votes pour chaque classe y_j . La marge varie entre -1 et $+1$ (Figure 2). De fortes valeurs positive ou négative de marge indiquent une forte confiance du classifieur pour la labellisation de l'instance x_i en tant que *limite* ou *non-limite* respectivement. Une valeur de marge proche de 0 indique une forte incertitude du classifieur.

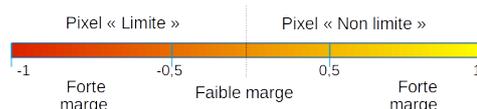


FIGURE 2 : Marge non supervisée - cas binaire.

3.2. Attributs utilisés

Trois types d'attributs image ont été testés : spectraux, basés sur le gradient et texturaux (Figure 3). Les quatre bandes initiales ont été utilisées comme attributs spectraux. Deux attributs basés sur le gradient ont été testés : un gradient récursif précédé par un filtrage gaussien ($\sigma = 2, 5$) et un gradient anisotrope basé sur la diffusion anisotrope de Perona-Malik (Perona and Malik, 1990) qui réduit la diffusion sur les pixels de contours. Enfin, la moyenne et la variance ont été considérées comme des attributs texturaux du premier ordre. Les filtres de Gabor et des filtres basés sur les descripteurs SIFT (Bris, 2012) ont également été testés et calculés sur la bande Pan à pleine résolution et sur les bandes multispectrales. Les attributs Pan sont ensuite ré-échantillonnés à la résolution multispectrale (2m).

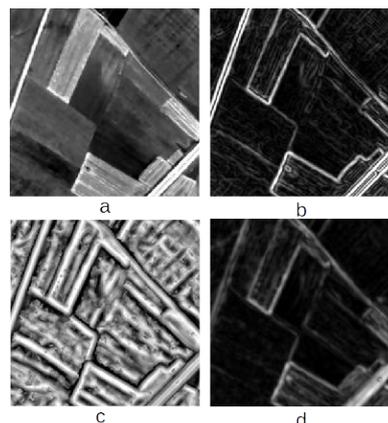


FIGURE 3 : Lot L06 - a) image panchromatique, b) gradient anisotrope c) attribut basé SIFT d) attribut par filtre de Gabor

3.3. Les stratégies d'apprentissage

Notre objectif est de détecter les limites parcellaires en utilisant une classification binaire en deux classes *Limite* Vs. *Non-limite*. La méthodologie proposée doit être

applicable à grande échelle sur des surfaces étendues. À cette échelle, des modifications radiométriques peuvent se produire sur les mêmes objets, entre différentes parties de l'image, en raison de changement du contexte local ou de la variabilité des limites parcellaires sur le terrain (levée de terre, végétation, ...).

Différentes stratégies d'apprentissage ont été testées ; 1) un modèle RF simple construit à partir d'un lot de parcelles adjacentes 2) un modèle RF global construit à partir de différents lots de parcelles géographiquement distants 3) un modèle RF simple enrichi par apprentissage actif. Pour toutes les stratégies, on doit tenir compte du très fort déséquilibre entre les populations des deux classes afin d'éviter le biais des performances du classifieur qui apparaît si une des classes est fortement représentée. Pour cela on constitue l'ensemble d'apprentissage avec le même nombre de pixels pour chacune des deux classes.

3.3.1. Modèle RF simple

Pour le modèle RF simple, les pixels d'apprentissage et de test considérés sont disjoints mais localisés dans le même lot de parcelles. Cette situation est la plus favorable puisque tous les types de limites sont représentés dans l'ensemble d'apprentissage.

3.3.2. Modèle RF global

Le modèle RF global utilise des lots de parcelles, choisies distantes géographiquement, pour former l'ensemble d'apprentissage. Pour chaque lot, le même nombre de pixels est retenu pour l'apprentissage. La taille totale de l'ensemble d'apprentissage est la même que celle du modèle simple. Les lots de parcelles restants sont utilisés comme ensemble de test.

3.3.3. Modèle RF enrichi par apprentissage actif

En classification d'images de télédétection, on est confronté à des différences de distributions des classes à travers l'image (phénomène de "datashift") (Tuia et al., 2011a) et la construction d'un modèle local s'avère sous optimale pour la classification d'une autre partie de l'image. Ce verrou est important à lever dans le cas de la classification à grande échelle. Pour cela, les techniques d'apprentissage actif (AL) paraissent bien adaptées et ont été appliquées avec succès en télédétection (Tuia et al., 2011b). L'apprentissage actif est basé sur une classification supervisée et consiste à enrichir l'ensemble d'apprentissage de façon itérative par les pixels les plus incertains et les plus difficiles à classer afin d'adapter le modèle de classifieur à ces cas difficiles tout en gardant des ensembles d'apprentissage relativement compacts.

Comme le montre la Figure 4, l'algorithme commence avec un petit nombre de pixels labellisés. Le classifieur est appliqué une fois. Une heuristique d'incertitude permet de garder les pixels non labellisés, les plus incertains c.à.d les plus difficiles à classer. Ces pixels

sont alors labellisés afin d'enrichir l'ensemble d'apprentissage. L'algorithme est itératif jusqu'à atteindre un critère d'arrêt (maximiser la précision de classification ou un nombre d'itérations prédéfini).

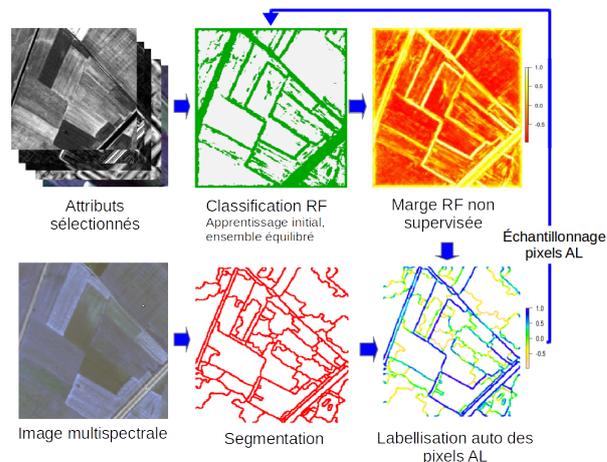


FIGURE 4 : Approche hybride combinant une approche région et la marge non supervisée des RF : labellisation automatique des pixels additionnels utilisés pour l'apprentissage actif (AL).

L'apprentissage actif a essentiellement été utilisé avec le classifieur SVM. Dans cette étude, on propose d'utiliser les forêts aléatoires. La marge d'ensemble non supervisée est utilisée comme mesure d'incertitude. Les pixels de faibles marges sont les plus informatifs et correspondent à des frontières de classes ou à des nouvelles classes non représentées dans l'apprentissage initial.

Dans notre approche, n pixels incertains sont sélectionnés aléatoirement dans un intervalle de faible marge prédéfini, pour chacune des classes *Limite* Vs. *Non-limite*. L'ensemble d'apprentissage reste donc toujours équilibré.

On propose ensuite une approche hybride innovante pour labelliser automatiquement les nouveaux pixels d'apprentissage actif. Elle combine la marge d'ensemble et une approche par région (i.e segmentation) pour labelliser automatiquement les pixels les plus incertains (Figure 4). Une segmentation hiérarchique est réalisée à partir des bandes spectrales initiales de l'image (Guigues et al., 2006). Un niveau d'échelle assez fin est retenu pour éviter les sous-segmentations.

Les pixels de faibles marges positives correspondant à une frontière de région segmentée seront labellisés comme *Limite*. Les pixels de faibles marges négatives hors frontières seront labellisés comme *Non-limite*.

4. Résultats et discussions

4.1. Importance de variables

L'idée consiste à tester trois types d'attributs image : spectraux, basés sur le gradient et texturaux et de mesurer l'importance de chacun des attributs pour notre classification binaire. L'importance des variables a été cal-

culée par des modèles RF simples et traitée indépendamment pour chaque lot de parcelles adjacentes. La médiane, la moyenne et l'écart-type des importances de chacune des variables ont été ensuite calculées sur l'ensemble des parcelles. Ceci permet d'avoir plus de robustesse dans le classement des attributs par importance.

Les résultats montrent que le classement d'un attribut par son importance peut varier d'un lot de parcelles à un autre. Cependant, on remarque que les trois groupes d'attributs sont toujours classés dans le même ordre (Figure 5).

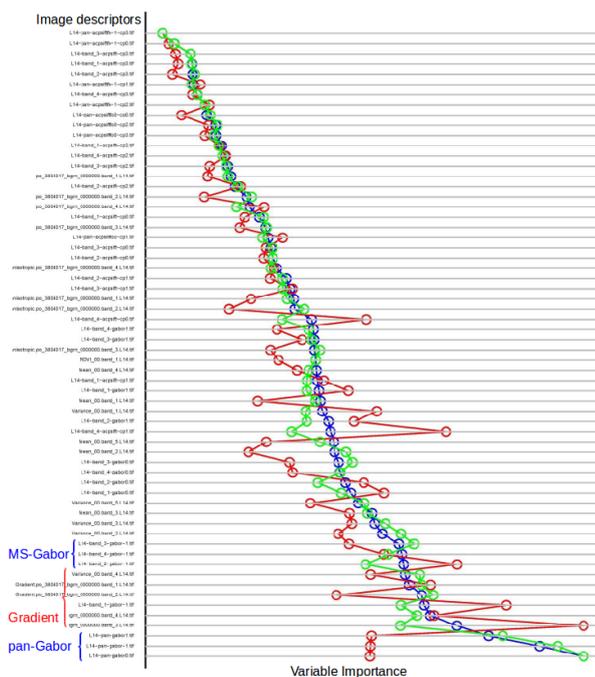


FIGURE 5 : Classement des attributs selon leur importance. La médiane, la moyenne et l'écart-type des importances sont illustrés en bleu, vert et rouge, respectivement.

Il apparaît que les filtres de Gabor aussi bien en Pan qu'en MS sont les plus appropriés pour la détection des limites parcellaires, suivis par les attributs basés sur le gradient récursif, essentiellement sur les bandes rouge et infrarouge, et enfin par la variance calculée sur toutes les bandes multispectrales. Le gradient récursif apparaît plus important que le gradient anisotrope puisque le filtrage Gaussien permet de lisser l'hétérogénéité intra-parcelle ainsi que les sillons de labour alors que le gradient anisotrope aura tendance à les maintenir et donc à être plus sensible à la variabilité intra parcellaire. Par ailleurs, les attributs basés sur des descripteurs SIFT ne sont pas pertinents puisqu'ils ont tendance à caractériser l'intérieur des régions et non leurs limites.

Ces résultats ont été confirmés par le calcul des importances de variables par le modèle RF global. Pour la suite de nos expériences, les attributs image suivants ont été retenus : la variance, le gradient récursif avec filtrage gaussien et les filtres de Gabor (Pan et MS).

4.2. Résultats de classification

Pour le modèle RF simple, 500 pixels par classe sont utilisés. Pour le modèle RF global, 100 pixels par classe et par lot d'apprentissage ont été retenus. En utilisant 5 lots d'apprentissage (en jaune sur la figure 1), on a 500 pixels d'apprentissage par classe également.

Pour l'apprentissage actif, le seuil de faible marge a été fixé à $m_{min} = 0,4$. Dans l'intervalle $[-m_{min}, m_{min}]$, $n = 50$ pixels sont retenus par classe pour chaque itération. Le nombre d'itérations est fixé à 10.

La Figure 6 montre l'application de différents modèles simples sur le lot de parcelles L01.

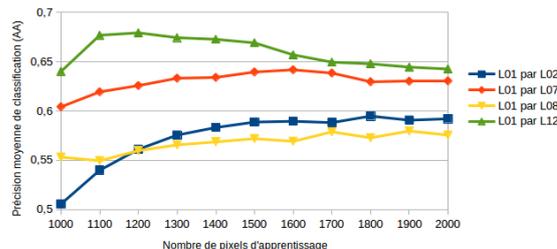


FIGURE 6 : Résultats de l'apprentissage actif sur le lot L01 en utilisant différents modèles simples.

On observe qu'en fonction de la représentativité du modèle initial, les précisions de classification varient de 50% à 63%. L'apprentissage actif permet d'améliorer les résultats de classification jusqu'à +9% en utilisant le lot L02. On remarque que la plupart des modèles finit par converger vers un palier sauf le modèle L12 (en vert sur la figure 6). Dans ce dernier cas, en rajoutant des pixels d'apprentissage uniquement sur le critère d'incertitude (marge), on introduit de la redondance entre ces pixels et les performances du classifieur peuvent se dégrader.

La Table 1 montre les résultats des différentes stratégies d'apprentissage pour les 5 lots test. Les précisions moyennes obtenues sont satisfaisantes. Le modèle "simple" est le plus favorable et conduit donc aux meilleures précisions de classification.

	L01	L03	L06	L09	L13
Simple	0.83	0.86	0.84	0.87	0.82
Simple autre	0.64	0.72	0.78	0.83	0.75
Simple autre (AL)	0.68	0.76	0.79	0.82	0.77
Global	0.64	0.75	0.78	0.84	0.77
Global (AL)	0.66	0.76	0.78	0.83	0.78

TABLE 1 : Comparaison des résultats de classification sur les 5 lots test avec différentes stratégies d'apprentissage : modèle simple avec même lot, modèle simple avec autre lot, modèle simple avec autre lot enrichi, modèle global, modèle global enrichi.

Les modèles "simple autre" et "global" ont des précisions similaires. L'approche par apprentissage actif donne de meilleures améliorations en partant du modèle simple.

Toutefois, il est intéressant de regarder de plus près les images de marges qui traduisent la confiance du clas-

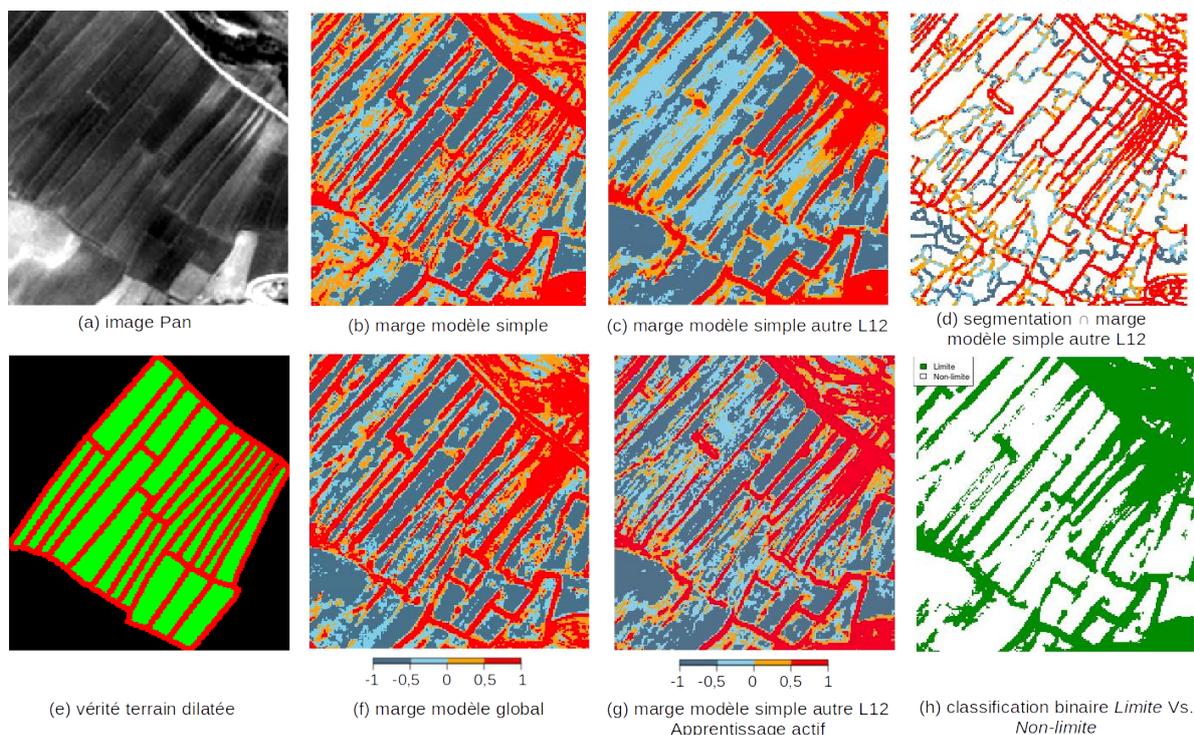


FIGURE 7 : Comparaison des différentes stratégies d'apprentissage sur le lot L13 par modèle simple et modèle global et par modèle simple L12 et enrichissement de ce dernier. © CNES (2013), distribution Airbus DS / Spot Image.

sifieur. La Figure 7 montre les images de marges obtenues sur le lot 13 avec les différentes stratégies (Figures 7b, 7c, 7f, 7g), une image de segmentation labellisée avec les valeurs de marges pour localiser les points d'apprentissage actif (Figure 7d) et la meilleure classification binaire obtenue (Figure 7h). On peut voir l'amélioration apportée par l'AL sur le modèle "simple autre" (Figures 7c et 7g). Le niveau de confiance sur l'intérieur des parcelles est beaucoup plus important mais également sur certaines limites qui apparaissent en rouge. On peut aussi voir les différences entre les modèles "simple" et "simple autre". Avec un apprentissage local et des fortes réponses saturées au niveau de la route, l'apprentissage est biaisé et son application sur les parcelles du bas renvoie beaucoup de limites (Figure 7b). Par contre quand on applique le modèle simple d'un autre lot, on est moins sensible à cet effet de saturation. Les parcelles du bas apparaissent correctes sur la carte de marge (Figure 7c) mais par contre on est moins certain sur l'intérieur des parcelles suite à un changement de pratiques agricoles ou de type de culture entre les deux lots par exemple. Par ailleurs, on peut voir que le modèle global (Figure 7f) est plus fin sur la discrimination des frontières le long de la route et est également plus robuste aux effets de saturation du lot L13.

Pour une utilisation opérationnelle, le modèle global RF s'avère intéressant. En effet, en pratique, une base de données présentant la variabilité des limites parcellaires pourrait être constituée et utilisée pour l'étape d'apprentissage. Si on reste dans le cas d'image mono-date,

l'apprentissage actif n'apporte pas de grandes améliorations sur ce modèle global par contre l'apport pourrait être plus important dans le cas d'image multitudes. Ce point sera validé dans de futurs travaux. Une autre option opérationnelle serait de disposer d'un sous-bassin versant bien renseigné sur le terrain et de l'utiliser pour construire un modèle simple et l'enrichir par apprentissage actif afin de l'appliquer efficacement à grande échelle.

5. Conclusion

Dans cette étude, nous avons proposé de détecter les limites des parcelles agricoles par une approche de classification supervisée. Dans l'objectif d'une utilisation opérationnelle à grande échelle, différentes stratégies d'apprentissage ont été proposées en incluant ou pas de l'apprentissage actif qui permet d'adapter le modèle localement. Les premiers résultats obtenus sont satisfaisants et permettent une bonne localisation des limites. On met surtout en évidence l'intérêt d'un modèle global si une base de données d'images de limites parcellaires existe. Par contre, si l'on dispose plutôt d'un sous bassin bien renseigné, on privilégiera le modèle simple enrichi.

Toutefois les résultats obtenus ne permettent pas d'aboutir au réseau parcellaire au niveau vectoriel. Il s'agit de résultats intermédiaires qui peuvent être utilisés dans un cadre de minimisation d'énergie de segmentation globale. Les cartes de marge pourraient être utilisées comme terme d'attache aux données et le terme d'a priori pourrait intégrer des critères de formes sur le parcellaire.

6. Remerciements

Les auteurs tiennent à remercier le CNES pour la mise à disposition des images Pléiades dans le cadre de l'étude RTU Pléiades.

Références

- Arbelaez, P., Maire, M., Fowlkes, C., Malik, J., 2011. Contour detection and hierarchical image segmentation. *IEEE PAMI* 33 (5), 898–916.
- Baatz, M., Schäpe, M., 2000. Multiresolution segmentation - An optimization approach for high quality multi-scale image segmentation. Strobl, J., Blaschke, T., Griesebner, G. (Eds) *Angewandte Geographische Informations - Verarbeitung XII*. Wichmann Verlag, Karlsruhe.
- Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multiresolution, object-oriented fuzzy analysis of remote sensing data for gis-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing* 58 (3-4), 239–258.
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65 (1), 2 – 16.
- Breiman, L., 2001. Random forests. *Machine Learning* 45 (1), 5–32.
- Bris, A. L., 2012. Extraction of vineyards out of aerial ortho-image using texture information. In : 22nd Congress of the ISPRS. Vol. I-3. ISPRS, Melbourne, Australia, pp. 383–388.
- Colin, F., Moussa, R., Louchart, X., 2012. Impact of the spatial arrangement of land management practices on surface runoff for small catchments. *Hydrological Processes* 26 (2), 255–271.
- Guigues, L., Cocquerez, J., Men, H. L., 2006. Scale-sets image analysis. *IJCV* 68 (3), 289–317.
- Guo, L., Chehata, N., Mallet, C., Boukir, S., 2011. Relevance of airborne lidar and image data for urban scene classification using random forests. *International Journal of Photogrammetry and Remote Sensing* 66 (1), 56–66.
- Mallinis, G., Koutsias, N., Tsakiri-Strati, M., Karteris, M., 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (2), 237–250.
- Perona, P., Malik, J., 1990. Scale-space and edge detection using anisotropic diffusion. *IEEE Trans. Pattern Anal. Mach. Intell.* 12 (7), 629–639.
- Trias-Sanz, R., Stamon, G., Louchet, J., 2008. Using colour, texture, and hierarchical segmentation for high-resolution remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (2), 156 – 168.
- Tuia, D., Pasolli, E., Emery, W., 2011a. Dataset shift adaptation with active queries. In : *Urban Remote Sensing Event (JURSE)*, 2011 Joint. Munich, Germany, pp. 121–124.
- Tuia, D., Volpi, M., Copa, L., Kanevski, M., Muñoz-Marí, J., 2011b. A survey of active learning algorithms for supervised remote sensing image classification. *IEEE JSTARS* 5 (3), 606–617.