

Détection de changements et classification sous-pixelliques en imagerie satellitaire. Application au suivi temporel des surfaces continentales.

Amandine Robin

Thèse co-encadrée par:
Sylvie Le Hégarat-Masclé et Lionel Moisan

21 mai 2007

Sommaire

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
- 3 Détection de changement sous-pixellique
- 4 Résultats
- 5 Conclusions et perspectives

Les enjeux

Suivi de la végétation :

- mise à jour de cartes,
- mise en œuvre de politiques agricoles,
- agriculture de précision.

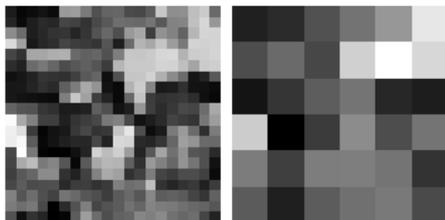


FIG.: De gauche à droite : Minnesota, Kansas, Allemagne (ASTER/Terra).

Les données



Images à **haute résolution spatiale (HR)**
(ex : 1 pixel $20 \times 20 m^2$),
faible fréquence temporelle
(env. 1 par mois).
Ex : SPOT/HRV, LandSat



Images à résolution spatiale
basse ou moyenne (BR)
(ex : 1 pixel pour $300 \times 300 m^2$),
haute fréquence temporelle
(env. 1 par jour).
Ex : SPOT/VGT, MeRIS

Les objectifs

Détecter et localiser les changements d'occupation du sol qui apparaissent sur la surface :

- coupes de forêts,
- rotation des cultures,
- infections (parasites, stress hydrique, etc)
- inondations, éruptions volcaniques, incendies, etc.

Remarque : La fréquence des observations nécessaires varie selon les phénomènes à étudier.

L'état de l'art

- Analyse en Composantes Principales,
- analyse du vecteur des changements,
- fusion de classifications.

Les limites :

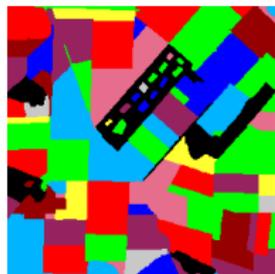
- difficulté du choix d'un seuil *a priori*,
- sensibilité à la variabilité *naturelle* des observations d'une année à l'autre (décalage des saisons, ...),
- sensibilité aux conditions d'illumination,
- absence de détection de changements sous-pixelliques.

Exemple : images SPOT/VGT

Plaine du Danube, Roumanie (base de données ADAM).

La problématique

Comparer une séquence d'images **BR** à une classification de référence **HR**



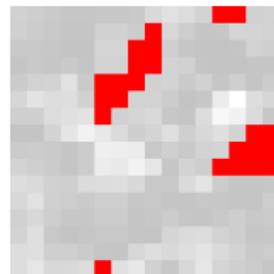
Classification HR

+



Séquence BR

⇒

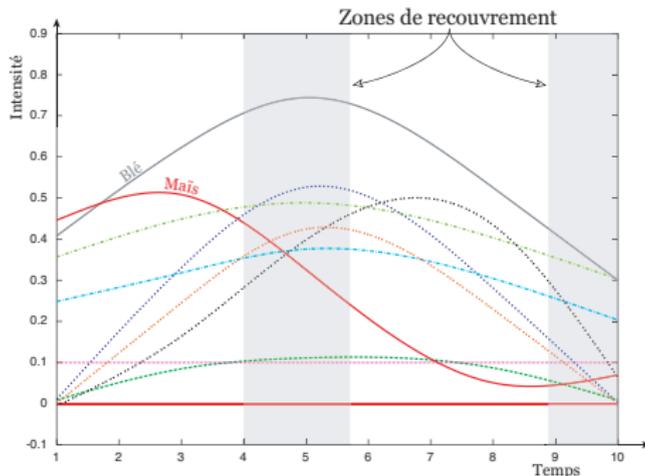


Pixels détectés

- 1 Contexte de l'étude
- 2 **Classification sous-pixellique**
 - La problématique
 - Modélisation
 - Résultats
- 3 Détection de changements sous-pixellique
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Motivation

Exploitation de l'information temporelle pour discriminer les différents types d'occupation du sol.



Décomposition du problème

Hypothèse

La structure géométrique d'une scène est invariante au cours du temps.



Segmentation HR
(donnée)

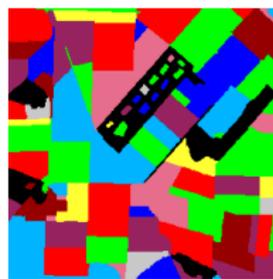
+



Séquence BR
(donnée)

⇒

nombre de
classes



Classification HR

- 1 Contexte de l'étude
- 2 Classification sous-pixellique**
 - La problématique
 - **Modélisation**
 - Résultats
- 3 Détection de changements sous-pixellique
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Estimation d'une séquence BR

Problème : La plupart des pixels BR représentent un mélange de plusieurs types d'occupation du sol.

Hypothèse (modèle linéaire de mélange)

L'intensité mesurée en un pixel BR y , à la date t , peut être estimée par

$$v_t(y) = \sum_{l \in \mathcal{L}} \alpha_l(y) m_t(l), \quad (1)$$

où

- $m = (m_t(l))_{t,l}$ représente l'intensité moyenne du label l à la date t ,
- $\alpha_l(y)$ représente le taux d'occupation du label l dans le pixel y
($\forall y, \sum_{l \in \mathcal{L}} \alpha_l(y) = 1$).

[Horwitz et al., 1971]

Maximum A Posteriori

Hypothèse

Les intensités mesurées en chaque pixel sont supposées **gaussiennes** et **indépendantes** (spatialement et temporellement).

Proposition

Sous les hypothèses précédentes, la classification optimale au sens du Maximum A Posteriori est déterminée par

$$\lambda^* = \arg \min_{\lambda \in L^S} \sum_{t \in \mathcal{T}} \sum_{y \in \mathcal{D}_{BR}} \left(\frac{(v_t(y) - \mu_t(\lambda, y))^2}{\sigma_t^2(\lambda, y)} + \ln(\sigma_t^2(\lambda, y)) \right) \quad (2)$$

où $\mu_t(\lambda, y) = \sum_{l \in \mathcal{L}} \alpha_l(y) m_t(l)$, et $\sigma_t^2(\lambda, y) = \frac{1}{N} \alpha_l(y) \text{var}_t(l)$, avec $N = \{\text{nombre de pixels HR dans un pixel BR}\}$.

Quelles dates exploiter ?

Quelles sont les dates les plus discriminantes ?

Une analyse probabiliste des erreurs montre que la fiabilité d'une telle classification dépend notamment de

$$\min_{l \neq l'} \sum_{i=1}^{\theta} |m_{t_i}(l) - m_{t_i}(l')|^2. \quad (3)$$

⇒ Choisir Θ dates parmi \mathcal{T} de manière à minimiser les erreurs de classification, *i.e.* en résolvant

$$\max_{t_1 < \dots < t_\theta} \min_{l \neq l'} \sum_{i=1}^{\theta} |m_{t_i}(l) - m_{t_i}(l')|^2. \quad (4)$$

Mise en œuvre

Cas supervisé : robustesse des moyennes et des variances des classes en présence de pixels mixtes ?

Cas non-supervisé :

- Hypothèse complémentaire : égalité des variances par classe
⇒ restriction aux statistiques d'ordre 1,
- Estimation des moyennes des classes,
- Minimisation de l'énergie (erreur quadratique) : problème combinatoire difficile.

⇒ Algorithme de **recuit simulé**, loi de température géométrique.

- 1 Contexte de l'étude
- 2 **Classification sous-pixellique**
 - La problématique
 - Modélisation
 - **Résultats**
- 3 Détection de changements sous-pixellique
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Résultats à partir d'images réelles et pseudo-réelles

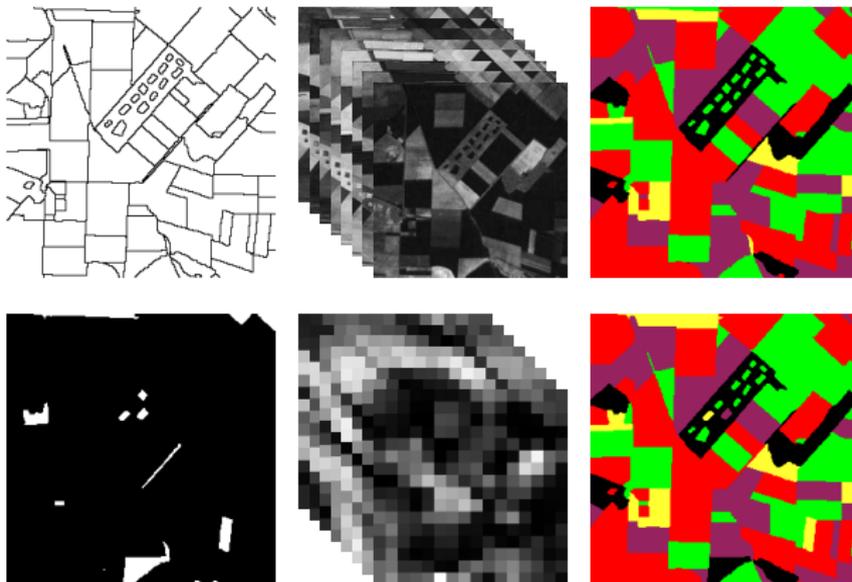


FIG.: Résultats obtenus à partir de 8 images réelles HR de taille 256×256 (en haut) et des mêmes images dégradées d'un facteur 16×16 (en bas, $\approx 12m$)

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
 - La problématique
 - Modélisation
 - Résultats
- 3 **Détection de changements sous-pixellique**
 - **Modélisation du problème**
 - Détection a contrario
 - Performances théoriques
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Estimation d'une image BR

Présentation du modèle dans le cas monotemporel.

Hypothèse (modèle linéaire de mélange)

L'intensité mesurée en un pixel BR y peut être estimée par

$$\hat{v}(y, m) = \sum_{l \in \mathcal{L}} \alpha_l(y) m_l, \quad (5)$$

où

- $m = (m_l)_{l \in \mathcal{L}}$ représente l'intensité moyenne du label l ,
- $\alpha_l(y)$ représente le taux d'occupation du label l dans le pixel y
($\forall y, \sum_{l \in \mathcal{L}} \alpha_l(y) = 1$).

Mesure de l'erreur réalisée

Soit $v_D = (v(y))_{y \in D}$ la restriction au sous-domaine $D \subset \mathcal{D}_{BR}$ de l'image observée v .

L'erreur minimale entre \hat{v} et v mesurée sur un sous-domaine D vaut alors

$$\delta(v_D) = \min_{m \in \mathbb{R}^L} \sqrt{\sum_{y \in D} (v(y) - \hat{v}(y, m))^2}. \quad (6)$$

Problèmes :

- Choix d'un seuil de détection sur l'erreur résiduelle $\delta(v_D)$,
- Comparaison de domaines de taille différente.

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
 - La problématique
 - Modélisation
 - Résultats
- 3 **Détection de changements sous-pixellique**
 - Modélisation du problème
 - **Détection a contrario**
 - Performances théoriques
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Approche a contrario

Principe de détection introduit en analyse d'images par [Desolneux et al., 2000].

Dans quel sous-domaine spatial $D \subset \mathcal{D}_{BR}$ l'image observée v est trop structurée pour être expliquée par le hasard ?

Principe :

- Adopter un modèle de fond pour les données (modèle a contrario),
- Détecter un sous-domaine de l'image s'il correspond à une grande déviation par rapport au modèle de fond.

Modèle a contrario

Définition (H_0)

Le modèle a contrario (H_0) pour l'image BR est un champ aléatoire V de $|\mathcal{D}_{BR}|$ variables gaussiennes i.i.d. $\mathcal{N}(m, \sigma^2)$ où $m \in \mathbb{R}$ et $\sigma > 0$ sont fixés.

Soit $\mathbb{P}_{H_0}(\delta(V_D) \geq \delta(v_D))$ la probabilité d'observer une erreur *étonnamment* faible sur le sous-domaine D .

À partir de quel seuil l'erreur n'est-elle plus acceptable ?

⇒ Normaliser cette p-valeur pour :

- contrôler le nombre moyen de fausses détections,
- éviter l'introduction d'un seuil *a priori*.

Nombre de fausses alarmes

La définition suivante a été introduite par [Grosjean et Moisan, 2006].

Définition

Soit $(X_i)_{1 \leq i \leq N}$ un ensemble de variables aléatoires. Une fonction $F(i, x)$ est un *NFA* (nombre de fausses alarmes) pour les variables aléatoires (X_i) si

$$\forall \varepsilon, \mathbb{E} [|\{i, F(i, X_i) \leq \varepsilon\}|] \leq \varepsilon. \quad (7)$$

Si une fonction F vérifie (7), alors la famille de tests $F(i, X_i) \leq \varepsilon$ garantit un nombre moyen de fausses alarmes inférieur à ε .

Nombre de fausses alarmes

Théorème

Soient $\eta : \mathbb{N} \rightarrow \mathbb{N}$ et, pour tout sous-domaine $D \subset \mathcal{D}_{BR}$, $\mathbb{P}_{H_0}[\delta(V_D) \geq \delta(v_D)]$ la probabilité d'observer une erreur minimale inférieure à $\delta(v_D)$ sous l'hypothèse H_0 . La relation

$$NFA(|D|) = \eta(|D|) \cdot \mathbb{P}_{H_0}[\delta(V_D) \geq \delta(v_D)] \quad (8)$$

définit un nombre de fausses alarmes dès que

$$\sum_{D \in \mathcal{D}_{BR}} \frac{1}{\eta(|D|)} \leq 1. \quad (9)$$

Soit $\varepsilon > 0$, un sous-domaine D de \mathcal{D}_{BR} est dit ε -**significatif** si $NFA(|D|) \leq \varepsilon$.

Choix du nombre de tests

Objectif : garantir en moyenne ε fausses détections.

- $\eta(|D|) = \#\{D \subset \mathcal{D}_{\text{BR}}\} = 2^{|\mathcal{D}_{\text{BR}}|}$
 - + répartition uniforme du risque sur tous les sous-domaines de \mathcal{D}_{BR} : $\forall D, \mathbb{P}_{H_0}(\delta(V_D) \geq \delta(v_D)) = \frac{\varepsilon}{|\mathcal{D}_{\text{BR}}|}$;
 - détection très improbable de sous-domaines très petits ou très grands.
- $\eta(|D|) = |\mathcal{D}_{\text{BR}}| C_{|\mathcal{D}_{\text{BR}}|}^{|D|}$
 - + répartition du risque uniformément par rapport à la taille des sous-domaines.

\Rightarrow On choisit $\eta(|D|) = |\mathcal{D}_{\text{BR}}| C_{|\mathcal{D}_{\text{BR}}|}^{|D|}$ de manière à comparer équitablement des sous-domaines de tailles différentes.

Choix du modèle a contrario

Choix des paramètres m et σ du modèle H_0 :

- H_0^a : m vecteur de $\mathbb{R}^{|\mathcal{D}_{BR}|}$ "constant", et σ quelconque,
- H_0^b : m et σ quelconques.

Proposition

Sous les hypothèses H_0^a ou H_0^b ,

$$NFA(|D|) = |\mathcal{D}_{BR}| C_{|\mathcal{D}_{BR}|}^{|\mathcal{D}|} \Gamma_{inc} \left(\frac{|\mathcal{D}| - L}{2}, \frac{\delta(v_D)^2}{2\sigma^2} \right), \quad (10)$$

où, pour tout $x \geq 0$ et $a > 0$, $\Gamma_{inc}(a, x) = \frac{1}{\Gamma(a)} \int_0^x e^{-t} t^{a-1} dt$.

⇒ On considère H_0 avec $m = 0$ et σ quelconque.

En pratique, $\sigma^2 =$ **variance de l'image BR** (rien ne doit être détecté dans une image de bruit blanc).

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
 - La problématique
 - Modélisation
 - Résultats
- 3 Détection de changements sous-pixellique**
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques**
 - Algorithme
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Modèle d'image

Supposons que toute image u s'écrit sous la forme

$$u = I + b, \quad (11)$$

où I est constante par morceaux et b une image de bruit gaussien.
Le NFA dépend principalement des paramètres suivants :

- la **taille** de l'image ($n = |\mathcal{D}_{BR}|$),
- la proportion de **pixels sans changement** dans l'image ($p \in [0, 1]$),
- le niveau de **contraste** de l'image ($c = \frac{\sigma_I}{\sigma_b}$).

Influence du niveau de contraste

Existe-t-il un seuil sur la proportion de changements dans l'image au-delà duquel on ne détecte plus rien ?

Proposition

Pour tout $n > 0$ et $p \in]\frac{L}{n}, 1]$ fixés,

$$\lim_{c \rightarrow +\infty} NFA(n) = 0. \quad (12)$$

⇒ Tout sous-domaine est détectable dès que le contraste de l'image est suffisamment fort.

Influence de la taille des images

Tout niveau de contraste peut-il être considéré ?

Proposition

Pour tout c fixé, il existe $p^*(c)$ tel que pour tout $p \in [p^*(c), 1[$,

$$\lim_{n \rightarrow +\infty} NFA(n) = 0. \quad (13)$$

⇒ Pour un niveau de contraste fixé, tout sous-domaine de changement représentant une proportion inférieure à $1 - p$ de l'image peut être détecté du moment que l'image est suffisamment grande.

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
 - La problématique
 - Modélisation
 - Résultats
- 3 Détection de changements sous-pixellique**
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques
 - Algorithme**
 - Optimisation
- 4 Résultats
- 5 Conclusions et perspectives

Problématique

Deux problèmes liés :

- Estimer les moyennes par label en présence de pixels de changement,
- Déterminer le sous-domaine qui minimise le *NFA*.

⇒ Stratégie de type RANSAC [Fischler et Bolles, 1981], [Moisan et Stival, 2004].

Idée

Utiliser un échantillon minimal (de taille L) pour estimer les moyennes et le compléter avec des données consistantes lorsque c'est possible. Itérer ce procédé un grand nombre de fois.

Algorithme monotemporel

Initialiser $\delta_{min}[]$ et NFA_{min} à $+\infty$ et $\delta = 0$;

Répéter N fois :

- tirer aléatoirement un ensemble I de L pixels de \mathcal{D}_{BR}
- estimer m pour $y \in I$ (matrice carrée)
- calculer $r(y) = (\hat{v}(y, m) - v(y))^2$ pour tout $y \in \mathcal{D}_{BR}$
- trier \mathcal{D}_{BR} en $(y_i)_{1 \leq i \leq |D|}$ par $r(y_i)$ croissants
- pour $k = L + 1$ à $k = |\mathcal{D}_{BR}|$
 - poser $\delta = \delta + r(y_k)$
 - si $\delta < \delta_{min}[k]$ alors
mettre à jour $\delta_{min}[k]$
si $NFA(k, \delta, \sigma) < NFA_{min}$ alors m.a.j. NFA_{min} et $D = \{y_i\}_{i=1..k}$
 - fin
- fin

fin

Minimum du *NFA*

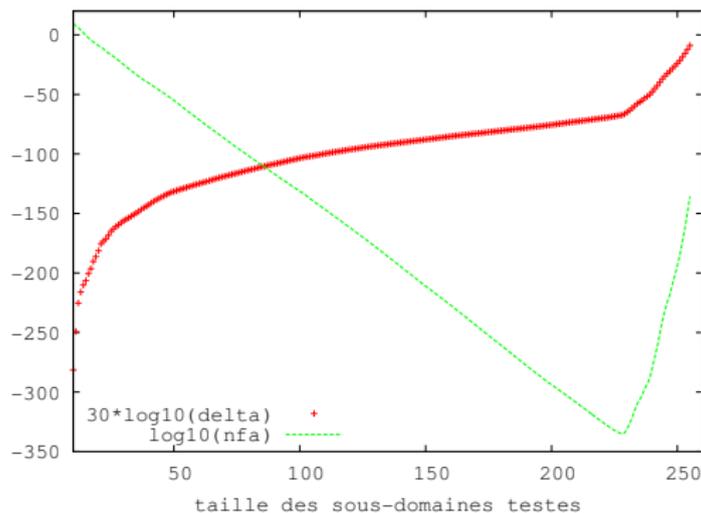


FIG.: Évolution des résidus quadratiques (en rouge) et du *NFA* (en vert).

- 1 Contexte de l'étude
- 2 Classification sous-pixellique
 - La problématique
 - Modélisation
 - Résultats
- 3 Détection de changements sous-pixellique**
 - Modélisation du problème
 - Détection a contrario
 - Performances théoriques
 - Algorithme
 - Optimisation**
- 4 Résultats
- 5 Conclusions et perspectives

Une stratégie de tirage

Principe : Pour chaque label, sélectionner un pixel dans l'ensemble des n pixels pour lesquels le rapport $\frac{\alpha_l(y_i)}{\max_{k \neq l} \alpha_k(y_i)}$ est le plus élevé.
Soit $A = (\alpha_l(y_i))_{i,l}$ la matrice des proportions,

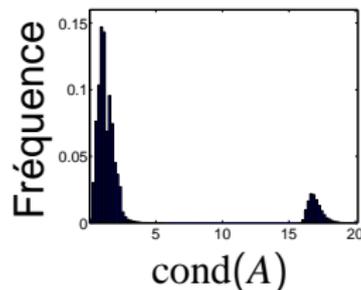
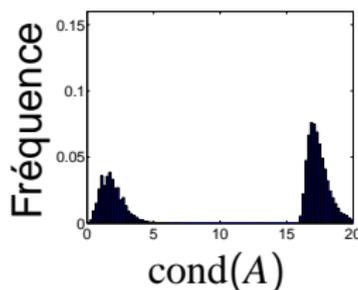


FIG. : Histogrammes obtenu pour 100 000 matrices de taille 6×6 (échelle log). À gauche : tirage aléatoire (11.5s.). À droite : stratégie (11.8s.).

Extension au cas multitemporel

Objectif : détecter une zone de changements même si seules certaines dates sont concernées.

⇒ détecter un sous-domaine spatio-temporel.

Hypothèse

Les images de la séquence sont parfaitement recalées.

Problème : choisir $\sigma^2 =$ variance de la séquence BR permet la détection de pixels de bruit.

Hypothèse

Le modèle a contrario pour la séquence BR est un champ aléatoire de $|\Omega|$ variables aléatoires gaussiennes i.i.d. $\mathcal{N}(0, 1)$.

Chaque image est alors normalisée par sa variance.

Images pseudo-réelles

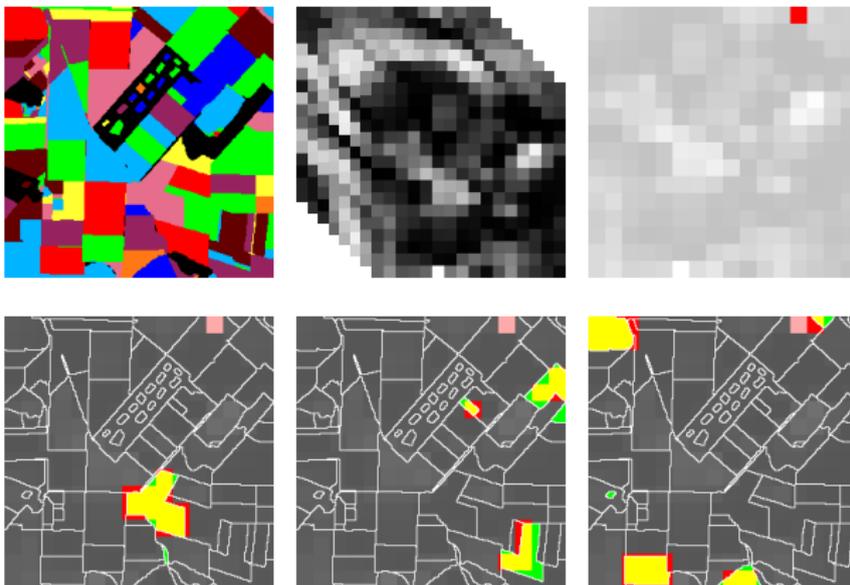


FIG.: Détection de changements simulés dans la classification HR.

Sensibilité au facteur de résolution

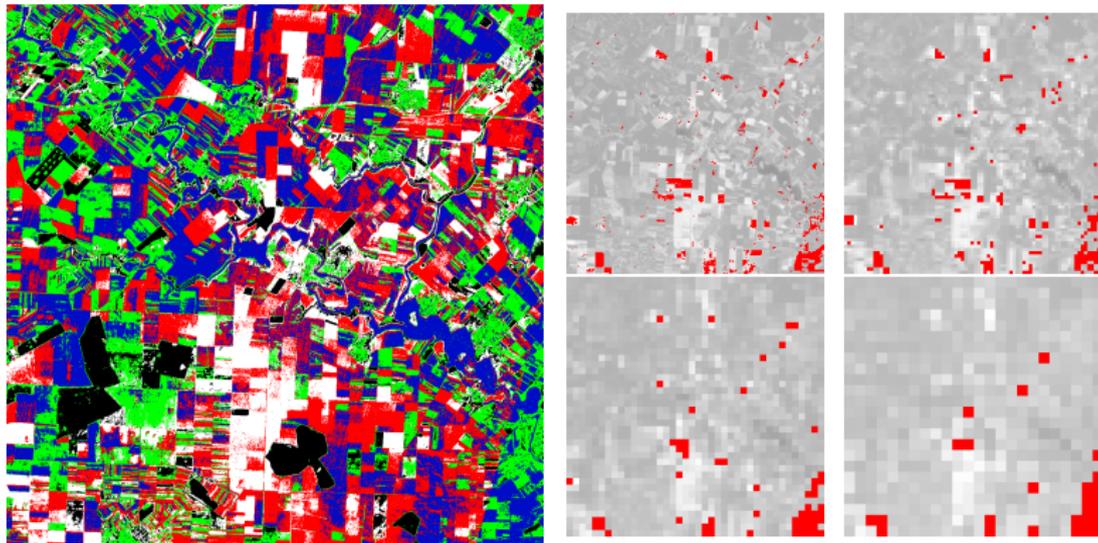


FIG.: A gauche : classification HR (15/10 et 14/11). A droite, changements détectés avec une image BR du 14/11 pour $N = 5, 15, 30, 50$.

Images SPOT/VGT

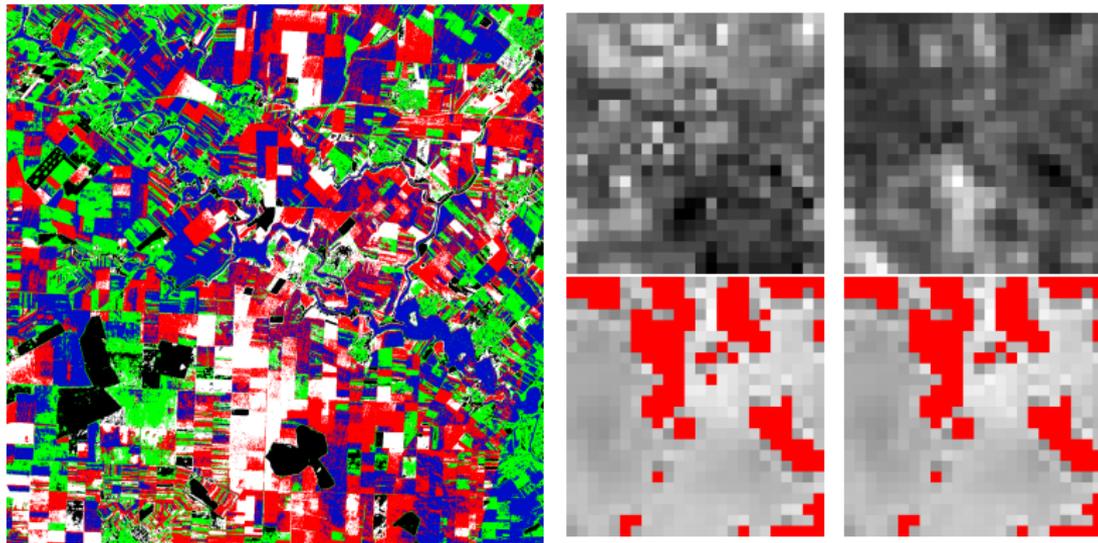


FIG.: A gauche, classification HR (15/10 et 14/11). A droite, détection avec les bandes *R* et *PIR* (VGT) du 11/11 (en haut) et du 01/12 (en bas). ~ 20s

Conclusions (1/2)

Dans cette thèse, on a proposé

- une méthode de classification :
 - qui permet de discriminer les types d'occupation du sol de régions sous-pixelliques,
 - capable, à partir d'images BR, d'obtenir des résultats très proches de ce qu'on obtiendrait à partir de données HR,
 - dont le seul paramètre est le nombre de classes,
 - dans les limites d'un rapport de résolution inférieur à 30,
 - sous réserve que les images soient bien recalées.

Conclusions (2/2)

- une méthode de détection de changements :
 - fondée sur l'analyse de la cohérence interne d'une séquence d'images,
 - qui ne nécessite pas d'information *a priori*,
 - sans paramètre,
 - capable de détecter des changements qui concernent des objets de taille sous-pixellique ($\geq 25\%$ du pixel BR),
 - robuste aux variations de contraste des images,
 - robuste à la proportion de pixels de changements dans l'image ($\leq 70\%$ de l'image),
 - une version optimisée de l'algorithme.

Perspectives

- Sur la classification :
 - exploiter les statistiques d'ordre 2 pour améliorer les résultats ?
 - exploiter les corrélations temporelles entre les images d'une séquence ?
 - utilité du critère *NFA* pour estimer le nombre de classes,
 - application à des images réelles du type MERIS.
- Sur la détection de changements :
 - étude de la robustesse de la détection vis-à-vis des erreurs de recalage,
 - confrontation à des situations réelles,
 - étude sur différents jeux de données, sur des séquences "complètes".