



**HAL**  
open science

# Discrimination de textures dans des images à Très Haute Résolution Spatiale pour l'analyse du changement

Antoine Lefebvre, Thomas Corpetti, Laurence Hubert-Moy

## ► To cite this version:

Antoine Lefebvre, Thomas Corpetti, Laurence Hubert-Moy. Discrimination de textures dans des images à Très Haute Résolution Spatiale pour l'analyse du changement. ORASIS'09 - Congrès des jeunes chercheurs en vision par ordinateur, 2009, Trégastel, France, France. inria-00404635

**HAL Id: inria-00404635**

**<https://inria.hal.science/inria-00404635v1>**

Submitted on 16 Jul 2009

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Discrimination de textures dans des images à Très Haute Résolution Spatiale pour l'analyse du changement

## Texture discrimination for change detection in Very High Resolution Images

Antoine Lefebvre

Thomas Corpetti

Laurence Hubert Moy

Laboratoire COSTEL, Université Rennes 2, UMR CNRS 6554 LETG, IFR 90 CAREN  
Place du Recteur Henri Le Moal 35043 Rennes cedex  
antoine.lefebvre@uhb.fr

### Résumé

Dans cet article, nous nous intéressons à l'analyse et à la détection du changement dans des images texturées issues de télédétection à très haute résolution spatiale. Le principe de l'approche mise en œuvre est de définir une mesure représentant les changements observés qui s'appuie sur les distributions des coefficients issus d'une décomposition en ondelette des images, en prenant soin d'être invariant par rotation. Les dissimilarités entre distributions sont obtenues au moyen de la distance de Kullback-Liebler et à partir de l'ensemble des différences entre distributions, un vecteur caractérisant le changement observé est défini. Nous présentons une application de cette mesure du changement en effectuant une classification des modifications observées (texture homogène à orientée, changement abrupt ou subtil) par d'arbres de décision s'appuyant sur le vecteur de mesure du changement proposé. Les expériences sont réalisées sur des photographies aériennes et confirment la capacité de la mesure définie à discriminer correctement les différentes textures et à interpréter le changement.

### Mots Clef

Détection de changement, analyse de texture, télédétection, transformée en ondelettes.

### Abstract

In this paper, we are interested in change detection in very high resolution remote sensing images using texture analysis. Our approach consists in defining a measure of the observed change which is based on the distribution of the coefficients issued from a wavelet transform, taking care to be rotation invariant. The distribution dissimilarities are obtained through the Kullback-Liebler distance and from all the dissimilarities, a change features vector is defined. We present an application of this measure of change using a decision tree to classify several changes (homogeneous or oriented texture, abrupt or subtle change) based on the proposed measure. The experiments are carried out on aerial photographs and bring out the efficiency of the mea-

sure to discriminate correctly the different textures and to interpret each change.

### Keywords

Change detection, texture analysis, remote sensing, wavelet transform.

## 1 Introduction

Dans le domaine du contrôle de l'occupation et de l'usage des sols, les images satellites s'avèrent être une donnée précieuse pour suivre les activités naturelles et anthropiques et mesurer les changements d'états du sol (générés par des catastrophes naturelles, l'étalement urbain des métropoles ou les modifications des parcelles agricoles par exemple). Cependant, l'utilisateur ne disposant que de l'information de luminance des images, la principale difficulté consiste à concevoir des approches objectives permettant de mesurer les quantités d'intérêts liées à un problème donné.

Dans cette étude, nous nous intéressons à la détection et à la caractérisation du changement observé entre deux objets, un "objet" correspondant ici à une entité géographique comme la parcelle agricole. Ces objets fournis en entrée représentent l'évolution d'un élément du paysage et proviennent en général de données acquises à plusieurs années d'intervalle, au moyen de capteurs ayant des propriétés spatiales et spectrales différentes. Par ailleurs, la forme de ces objets est susceptible d'évoluer au cours du temps. Ces contraintes sont donc à prendre en considération dans la conception de la méthode et il sera par exemple impossible de comparer directement les intensités point par point car les dimensions des objets peuvent être totalement différentes. Ainsi, seuls des propriétés sur l'organisation spatiale pourront être comparées.

Actuellement, la majorité des méthodes utilisées de manière routinière par les utilisateurs pour détecter le changement a été élaborée pour mettre en évidence des changements abrupts d'occupation du sol à partir d'images à basse ou moyenne résolution [3, 12]. Avec ce type de données, les objets géographiques qui composent l'image sont repré-

sentés par un ou plusieurs pixels uniformes et les méthodes utilisées reposent sur une analyse statistique où chaque pixel est traité de manière indépendante. Il est évident que de telles approches ne sont pas adaptées aux images issues de capteurs à Très Haute Résolution Spatiale (THRS) tels que Quickbird, Geoeye ou Worldview.

L'objectif de cette étude est de développer une mesure facilement implémentable de manière routinière capable de capturer la nature du changement observé entre deux objets géographiques de dimension différente et provenant de différents capteurs. Nous supposons que ces objets ont été préalablement segmentés sur une image à l'aide d'une technique dédiée (en pratique, la segmentation est effectuée par un logiciel de télédétection comme ENVI ou eCognition). Nous présentons une application de cette mesure pour caractériser le changement à partir d'arbres de décisions.

La méthodologie retenue s'appuie sur la comparaison des différentes textures contenues dans ces objets. Sur une image de télédétection à THRS, la couverture du sol n'est en effet pas uniforme et l'image représentant une entité géographique résulte d'un ensemble d'éléments (trop petits pour être identifiés individuellement) tels que de l'herbe, les habitations, feuillage, le sable qui se caractérisent par le biais de leur texture.

Il est possible de décrire une texture selon la distribution de sa fonction de luminance et selon l'échelle associée aux motifs composant cette texture. Dans le cadre de cette étude, nous supposons qu'une texture peut être soit orientée, dans le cas où l'on retrouve une certaine périodicité dans une direction donnée, soit homogène dans le cas où l'organisation de la luminance ne privilégie pas de direction particulière. Par ailleurs, un même objet peut comporter plusieurs distributions en fonction des échelles d'analyse. Par exemple, un champ de céréale observé à partir d'une image à THRS possède à petite échelle une texture homogène qui représente l'organisation du feuillage tandis qu'à grande échelle, on observe une texture orientée qui représente les traces de passage d'engins agricoles et les surfaces cultivées. L'analyse à mettre en œuvre doit ainsi être capable de synthétiser correctement les différentes distributions possibles à plusieurs niveaux d'échelles. Nous imposons également une insensibilité à l'angle d'orientation des textures. En effet, si l'on prend l'exemple de parcelles agricoles, quelque soit le sens de labour et de culture des éléments de cette parcelle agricole, la nature du couvert reste la même.

Parmi les nombreuses approches existantes pour caractériser des textures (voir par exemple [9, 15, 17, 20] pour quelques reviews), nous nous appuyons ici sur une analyse des coefficients issus d'une décomposition en ondelettes des images car ces approches se sont révélées fructueuses [1, 11, 16, 19] et en particulier pour les images satellites [13]. La technique que nous proposons repose sur des indicateurs issus de mesures de similarité entre les distributions des coefficients d'ondelettes. Afin d'assurer l'invariance par

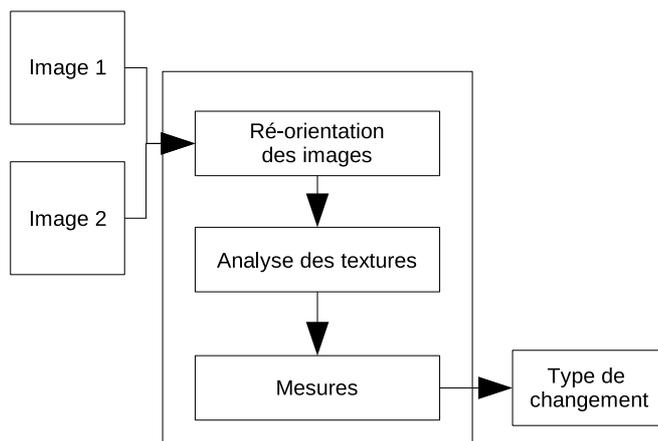


FIG. 1 – Schéma général de la méthode de détection et de caractérisation du changement

rotation, nous réorientons les objets en entrée de manière à ce que l'orientation dominante soit d'un angle imposé par défaut. Cela est réalisée par une analyse en composante principale de la transformée de Fourier des images. Enfin, la caractérisation du changement est menée au moyen d'arbres de décisions à partir d'exemples tests. La méthode que nous proposons se décompose donc en trois phases, comme cela est décrit dans la figure 1.

L'article est structuré de la manière suivante : la ré-orientation des images est décrite dans la section 2, l'analyse des caractéristiques texturales des objets est présentée dans la partie 3 et la mesure capturant le changement est décrite dans la section 4. Enfin, nous présentons une application de cette mesure pour déterminer et caractériser le changement à l'aide d'arbres de décisions dans la partie 5.

## 2 Orientation dominante des images

Le but de cette section est de déterminer l'orientation globale des textures contenues dans les objets à analyser afin d'assurer une invariance par rotation (pour ne pas être sensible, par exemple, au sens de labour d'une parcelle agricole). De nombreux outils performants existent pour déterminer l'orientation de motifs texturés (voir par exemple [6, 8]) mais ceux-ci associent en général à chaque position de l'image un angle. Dans notre cas, nous souhaitons simplement déterminer l'orientation globale des motifs de l'objet.

Si un objet se compose d'une texture homogène et de quelques motifs orientés, alors les fréquences correspondantes à l'angle d'orientation dans son spectre de Fourier auront un comportement singulier. Ainsi, similairement à [10], nous cherchons l'angle qui contient le plus d'énergie dans le spectre de Fourier de l'image initiale. La recherche de cet angle s'effectue par analyse en composantes principales (ACP) sur le spectre de Fourier. Une rotation dans l'espace de Fourier se traduisant par une rotation de même angle dans l'espace image, nous pouvons ainsi recaler nos objets en entrée afin que leur orientation principale

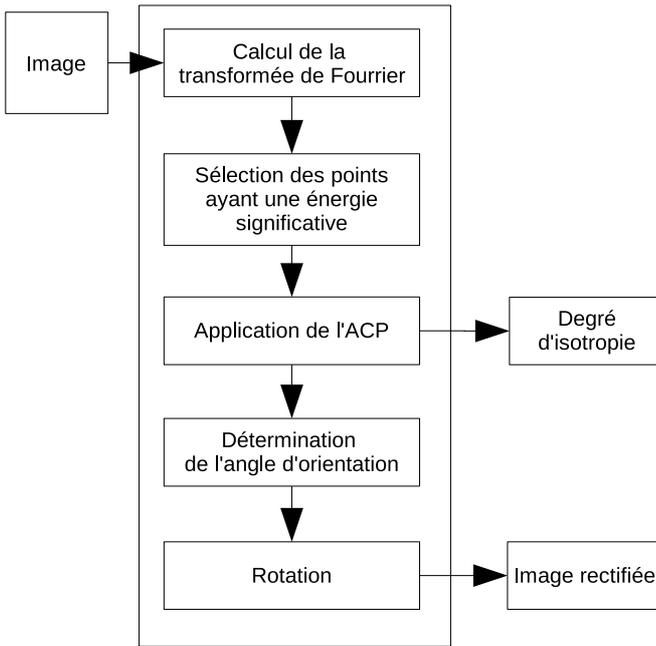


FIG. 2 – Bloc d’analyse primaire

soit identique. Par ailleurs, l’ACP permet de quantifier, en fonction du rapport des valeurs propres associées à chaque direction, un degré d’anisotropie des motifs présents dans l’image : si les deux composantes contiennent sensiblement la même quantité d’information, alors la texture sera homogène et à l’inverse, si une orientation est privilégiée, alors le rapport entre les deux premières valeurs propres sera élevé. Le principe de cette approche est décrit dans le diagramme de la figure 2. Seuls les points dont l’énergie est significative sont conservés pour effectuer l’ACP afin de réaliser cette étape rapidement. Nous réorientons notre spectre afin d’obtenir une orientation principale sur l’abscisse, ce qui correspond à une orientation des motifs dans le sens vertical dans l’espace image. Le haut de la figure 3 donne un exemple sur une image réelle où une orientation particulière est privilégiée et le bas correspond au cas d’une texture non orientée. Nous avons validé cette approche sur une série de 60 textures orientées et 80 textures homogènes. Cette étape s’est déroulée avec succès puisque l’ensemble des textures orientées a été correctement réarrangé. Par ailleurs, si le rapport entre les valeurs propres est supérieur à un certain seuil (en pratique, nous choisissons 80 % de la variance totale), alors nous considérons qu’une orientation particulière est privilégiée.

Lorsque cette étape est réalisée, les objets possèdent tous la même orientation principale. La prochaine étape consiste à représenter les textures contenues dans chaque élément.

### 3 Description des textures

Le but de cette section est de caractériser le contenu textural de chaque objet. Notons que l’étape précédente fournit une première description grossière : il est en effet possible

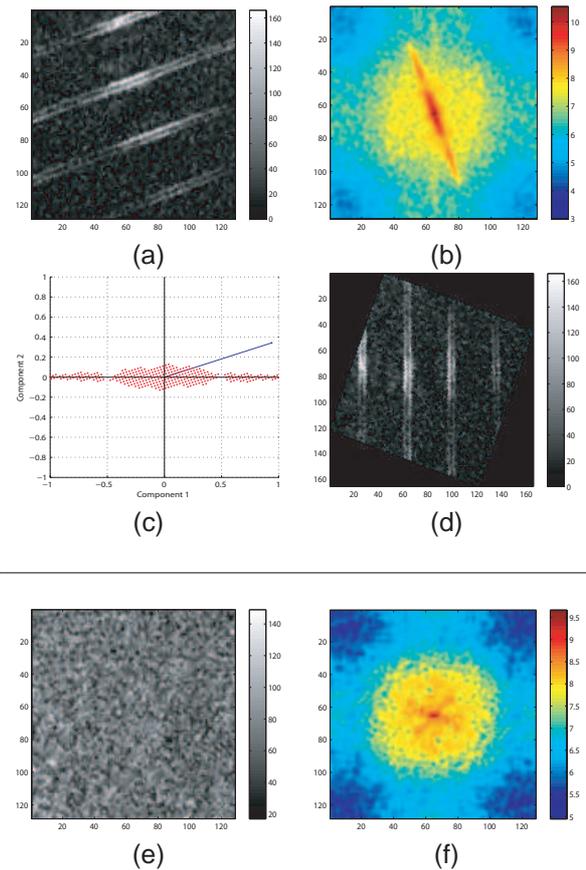


FIG. 3 – Détermination de l’orientation dominante de l’image. (a) : une image texturée orientée ; (b) sa transformée de Fourier, on aperçoit clairement une direction privilégiée ; (c) les composantes ayant servi à l’acp réorientés sur l’abscisse et (d) : l’image résultante ; (e) une image texturée où aucune direction n’est privilégiée ; (f) sa transformée de Fourier, qui est distribuée de manière isotrope. L’angle moyen n’est pas significatif et n’affecte pas les propriétés de texture de l’image

de déterminer si les éléments analysés sont homogènes ou orientés du point de vue de leur texture. Cette première classification sera utile par la suite pour caractériser les différents types de changements observés.

Il existe de nombreuses solutions pour décrire des textures en vision par ordinateur. Les descripteurs classiques sont en général issus de modèles statistiques [4] ou bien de la théorie de filtrage où l’image est décomposée sur des bancs des filtres. Parmi ces dernières méthodes, le filtre de Gabor ou la décomposition en ondelettes sont les techniques les plus fréquemment utilisées et ont été appliquées avec succès pour la description de textures [1, 11, 13, 16, 19]. L’analyse multi-résolution associée à la décomposition en ondelettes est adaptée à notre problématique puisque nos objets se composent de plusieurs éléments associés à différentes échelles spatiales.

#### Décomposition en ondelettes

En notant  $I_0$  une image, celle-ci peut se décomposer de la

manière suivante :

$$I_0 = \sum_n I_{J,n} \phi_{J,n} + \sum_{j=-J}^{-1} \sum_n w_{j,n} \psi_{j,n} \quad (1)$$

pour une décomposition en ondelettes d'ordre  $J$  où  $\psi$  est la fonction analysante issue de l'ondelette mère et  $\phi$  la fonction d'échelle. Une image  $I_0$  peut donc être représentée par la série  $\{I_{J,n}, w_{j,n}\}$ ,  $-J \leq j \leq -1$ . En pratique, la série  $I_{J,n}$  comporte l'image dite d'"approximation" après la décomposition en  $J$  niveaux et les séries  $w_{j,n}$ ,  $J \leq j \leq -1$  comportent les coefficients liés aux détails dans les différentes échelles spatiales  $j$  et dans les directions horizontales, verticales et diagonales. Dans notre étude, étant donné que les images d'entrées sont susceptibles de provenir de capteurs différents et peuvent être acquises à différents instants de l'année, nous avons choisi de ne pas tenir compte de l'information d'approximation qui contient uniquement les propriétés de luminance moyenne des structures et qui en général est dépendante du type de capteur utilisé. L'information sur la distribution spatiale des structures, et donc sur la texture, est quant à elle contenue dans les séries  $w_{j,n}$ .

### Description de la texture

Afin de caractériser l'information contenue dans  $w_{j,n}$ , nous exploitons les constats effectués dans [14, 21] où les auteurs vérifient que la densité gaussienne généralisée (GGD) est une approximation fiable de distribution des coefficients  $w_{j,n}$  dans les différentes sous bandes de la décomposition en ondelettes. La GGD s'exprime par :

$$p(x; \alpha, \beta) = \frac{\beta}{2\alpha\Gamma(1/\beta)} e^{-\left(\frac{|x|}{\alpha}\right)^\beta}, \quad (2)$$

où  $\Gamma(t) = \int_0^{+\infty} e^{-z} z^{t-1} dz$  est la fonction "gamma",  $\alpha$  est le paramètre d'échelle et  $\beta$  est le paramètre de forme. Ainsi, chaque série  $w_{j,n}$  ne peut être représentée que par les deux coefficients  $(\alpha, \beta)$ . Plusieurs méthodes peuvent être employées pour identifier les paramètres  $(\alpha, \beta)$  à partir d'une distribution, comme la technique de moments ou l'estimateur du maximum de vraisemblance. Dans nos expériences, nous avons observé que la première méthode n'a pas donné de bons résultats. Nous avons ainsi préféré utiliser l'estimateur du maximum de vraisemblance.

La fonction de log-vraisemblance est définie par  $\mathcal{L}(\mathbf{x}, \alpha, \beta) = \log \prod p(x_i; \alpha, \beta)$  pour l'ensemble des coefficients  $\mathbf{x} = (x_1, \dots, x_N)$ . Les paramètres  $(\alpha, \beta)$  sont ainsi obtenus en résolvant le système suivant [22] :

$$\frac{\partial \mathcal{L}(\cdot)}{\partial \alpha} = -\frac{N}{\alpha} + \sum_{i=1}^N \frac{\beta |x_i|^\beta \alpha^{-\beta}}{\alpha} = 0, \quad (3)$$

$$\frac{\partial \mathcal{L}(\cdot)}{\partial \beta} = \frac{N}{\beta} + \frac{N\Psi(1/\beta)}{\beta^2} - \sum_{i=1}^N \left(\frac{|x_i|}{\alpha}\right)^\beta \log\left(\frac{|x_i|}{\alpha}\right) = 0, \quad (4)$$

où  $\mathcal{L}(\cdot) = \mathcal{L}(\mathbf{x}, \alpha, \beta)$  et  $\Psi(t) = \Gamma'(t)/\Gamma(t)$  est la fonction digamma. Lorsque  $\beta$  est fixé, l'équation (3) possède une

solution unique  $\hat{\alpha} = \left(\frac{\beta}{N} \sum_{i=1}^N |x_i|^\beta\right)^{1/\beta}$ . En substituant cette relation dans (4),  $\hat{\beta}$  est la racine de :

$$1 + \frac{\Psi(1/\beta)}{\beta} - \frac{\sum_{i=1}^N |x_i|^\beta \log |x_i|}{\sum_{i=1}^N |x_i|^\beta} + \frac{\log\left(\frac{\beta}{N} \sum_{i=1}^N |x_i|^\beta\right)}{\beta} = 0 \quad (5)$$

qui est résolue numériquement en utilisant la procédure de Newton-Raphson, comme cela est présenté dans [5]. Afin d'accélérer la convergence, l'initialisation du paramètre  $\beta_0$  est obtenue par la technique des moments. Ainsi, pour chaque objet fourni, une série  $(\alpha_{j,z}, \beta_{j,z})$  où  $J \leq j \leq -1$  représente l'échelle d'analyse et  $Z = (H, V, D)$  représente l'orientation est disponible.

La représentation de la distribution des coefficients par la série  $(\alpha_{j,z}, \beta_{j,z})$  permet une description compacte de la distribution et permet également d'être plus robuste aux données aberrantes. En pratique, nous utilisons cette représentation seulement pour les deux premiers niveaux de la décomposition en ondelettes. En effet, les valeurs coefficients  $w_{j,n}$  des niveaux supérieurs sont susceptibles de contenir, en plus des informations liées à la texture, des données liées aux structures des images et cela ne garantit plus un comportement sous forme de GGD<sup>1</sup>. Ces descripteurs de la texture nous servent ensuite à définir un vecteur représentatif du changement observé entre deux objets.

## 4 Vecteur de mesure du changement

### Quantification du changement

Pour une décomposition en ondelettes en  $J$  niveaux, nous disposons de  $3J$  descriptions de la distribution des coefficients  $w_{j,n}$  dans les bandes horizontales, verticales et diagonales. Ces descriptions sont représentées par les paramètres  $(\alpha, \beta)$  d'échelles et de forme de la relation (2) pour les deux premiers niveaux et directement par les valeurs  $w_{j,n}$  pour les niveaux supérieurs. Afin de comparer les histogrammes entre eux et donc de quantifier la nature du changement, nous avons utilisé la distance de Kullback-Liebler définie pour deux distributions  $p_1$  et  $p_2$  par :

$$KL(p_1, p_2) = \int p_1(x) \log \frac{p_1(x)}{p_2(x)} dx.$$

Dans le cas de Gaussiennes Généralisées représentées par  $(\alpha_1, \beta_1)$  et  $(\alpha_2, \beta_2)$ , cette distance s'écrit :

$$KL(\alpha_1, \beta_1, \alpha_2, \beta_2) = \log \left( \frac{\beta_1 \alpha_2 \Gamma(1/\beta_2)}{\beta_2 \alpha_1 \Gamma(1/\beta_1)} \right) + \left( \frac{\alpha_1}{\alpha_2} \right)^{\beta_2} \frac{\Gamma((\beta_2 + 1)/\beta_1)}{\Gamma(1/\beta_1)} - \frac{1}{\beta_1}.$$

La distance de Kullback-Liebler est non symétrique et la mesure de similitude que nous avons retenue est

<sup>1</sup>Notons que le nombre optimal  $j$  de niveaux de décomposition à utiliser pour utiliser la représentation par une GGD peut aisément s'obtenir de manière automatique à partir de l'erreur entre la distribution initiale et sa représentation par GGD.

$KLS(p_1, p_2) = KL(p_1, p_2) + KL(p_2, p_1)$ . Cette quantité est nulle pour deux distributions identiques et grandit progressivement quand les distributions diffèrent.

### Vecteur de mesure du changement

A partir des distances obtenues à chaque niveau de la décomposition, nous souhaitons discriminer les changements en fonction de leur distribution, échelle et intensité. On admet qu'un changement peut se produire à *petite échelle*, à *grande échelle* ou les deux à la fois. Pour identifier sa nature, on définit comme *changement orienté* le passage d'une texture homogène vers une texture orientée. L'intensité indique la ressemblance moyenne entre les 2 textures, le changement est *subtil* lorsque les similitudes en terme de distribution et/ou d'échelle sont fortes, à l'inverse le changement est *abrupt*. Pour cela, nous retenons un vecteur  $\mathcal{D}$  composé de :

- la moyenne de l'ensemble des  $KLS$  (afin de discriminer un changement abrupt d'un changement subtil) ;
- le rapport entre la dissimilarité d'une composante par la somme des dissimilarités des 12 autres (pour mettre en évidence les composantes qui mesurent au mieux les différences entre textures) ;
- l'écart-type des dissimilarités entre les différents niveaux d'échelle pour un même type de détail (horizontal, vertical ou diagonal) afin de détecter les changements se produisant seulement dans certains niveaux d'échelle ;
- l'écart-type des dissimilarités d'un même niveau d'échelle dans les 3 types de détails pour détecter les changements qui se produisent seulement dans une direction particulière ;
- le degré d'isotropie des textures calculé par le rapport entre les valeurs propres issues de l'ACP de la méthode de la section 2.

Toutes ces mesures permettent d'isoler les différentes configurations de changements que nous sommes susceptibles de rencontrer. Par exemple, un changement abrupt à grande échelle entre deux textures homogènes possédera des erreurs entre détails de même nature qui augmenteront avec l'échelle d'analyse, comme illustré sur la figure 4 pour les détails diagonaux. Dans ce cas, les valeurs les plus significatives du vecteur de changement  $\mathcal{D}$  apparaissent dans l'écart-type des dissimilarités entre les différents niveaux d'échelle des détails et dans le rapport des composantes des derniers niveaux. De la même manière, un changement subtil de type orienté (comme le passage d'une prairie à une prairie semée) fera intervenir des valeurs caractéristiques dans l'écart-type des dissimilarités d'un même niveau d'échelle et dans le rapport de la composante verticale (car les objets sont réorientés selon cet axe) du dernier niveau de décomposition comme illustré sur la figure 5. Afin de valider la mesure du changement proposée par le vecteur  $\mathcal{D}$ , la section suivante présente une application de cette métrique dans des arbres de décision pour effectuer une classification des différents types de changements.

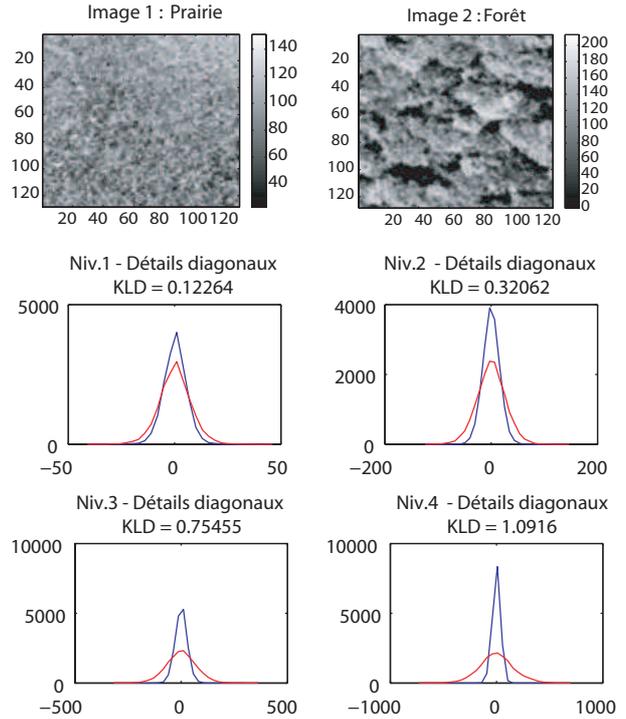


FIG. 4 – Exemple d'un changement abrupt entre deux textures homogènes (prairie et forêt). Les différences entre histogrammes des détails (diagonaux ici) augmentent avec l'amplitude de l'échelle d'analyse.

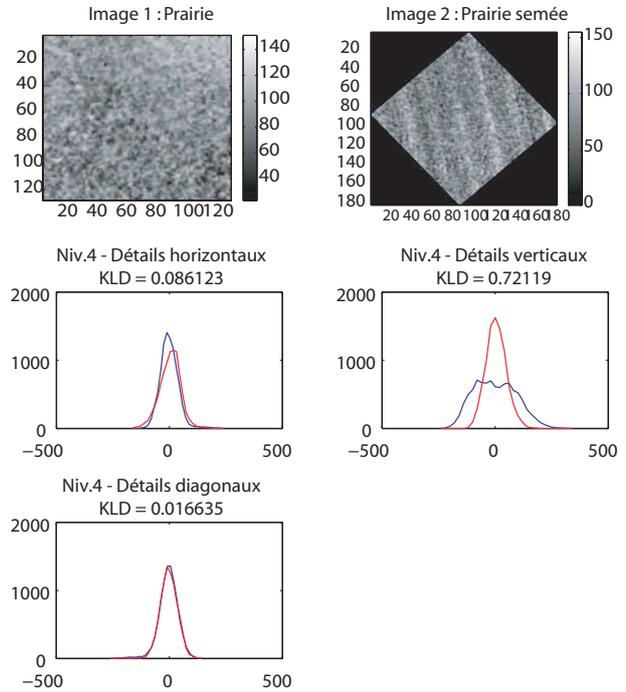


FIG. 5 – Exemple d'un changement subtil de type orienté détecté à grande échelle (prairie à prairie semée). Histogrammes des composantes des détails dans le quatrième niveau de la décomposition. On voit clairement apparaître un changement dans l'orientation des structures.

## 5 Classification du changement par arbres de décisions

Cette partie est une application du vecteur de changement  $\mathcal{D}$  proposé dans la section précédente. L'objectif est de caractériser les modifications observées sur des objets issus de photographies aériennes acquises par l'Institut Géographique National. Nous nous focalisons sur des parcelles agricoles, à une résolution spatiale de 50 cm. Nous avons isolé six types de textures pour représenter le couvert végétal : céréale, prairie, prairie semée, maïs, maïs traité et forêt (cf figure 6). Bien que différentes, ces textures possèdent certaines caractéristiques communes : par exemple, la texture de céréale et de maïs traité sont orientées à grande échelle alors que celle de prairie et de maïs ne le sont pas. A petite échelle, la texture de céréale et de prairie sont proches, tout comme l'est celle de maïs et de maïs traité. Par ailleurs, cinq types de changements sont susceptibles d'apparaître : 1 - changement à grande échelle, abrupt et orienté (ex : passage d'une céréale à une prairie –semée ou non–) ; 2 - changement à grande échelle, subtil et orienté (ex : passage d'une prairie à une prairie semée) ; 3 - changement entre deux textures homogènes à la même échelle (ex : passage du maïs à une prairie) ; 4 - changement à grande et petite échelle, abrupt et orienté (ex : passage d'un maïs traité à une prairie) ; 5 - changement à grande échelle entre deux textures homogènes (ex : passage d'une prairie à une forêt).

Nous avons choisi d'effectuer la classification des différents types de changements en utilisant des arbres de décision qui s'appuient sur le vecteur  $\mathcal{D}$ . Les arbres de décision sont des techniques de classification par apprentissage. Le principe est de décomposer le problème de classification en une série de tests conduisant à une partition de l'espace des données en sous-régions homogènes en terme de classe. Les différents tests sont représentés par les nœuds et les feuilles correspondent à une classe majoritaire. Pour plus de détails sur les arbres de décision et leur construction, nous renvoyons le lecteur à [2, 7, 18]. Dans cette application, pour chaque classe de texture, un ensemble de 20 échantillons est choisi. Les mesures de dissimilarité sont calculées sur l'ensemble des paires d'échantillons, chaque comparaison ainsi correspond à une série de 400 tests. Il est à noter que la réorientation des images décrite dans la section 2 a été appliquée au préalable à toutes les données en entrée.

Deux classifications sont réalisées. Dans la première classification l'ensemble des tests est utilisé pour l'élaboration et la validation du modèle alors que pour la seconde, l'élaboration du modèle est réalisée sur 30 % des tests et validé sur les 70 % restants. La figure 7 met en relation les taux d'erreur des 2 classifications avec le nombre de nœuds terminaux de l'arbre. Nous observons que le taux d'erreur de la première classification diminue constamment au fur et à mesure que le nombre de nœuds augmente. En revanche, le taux d'erreur de la seconde classification diminue rapi-

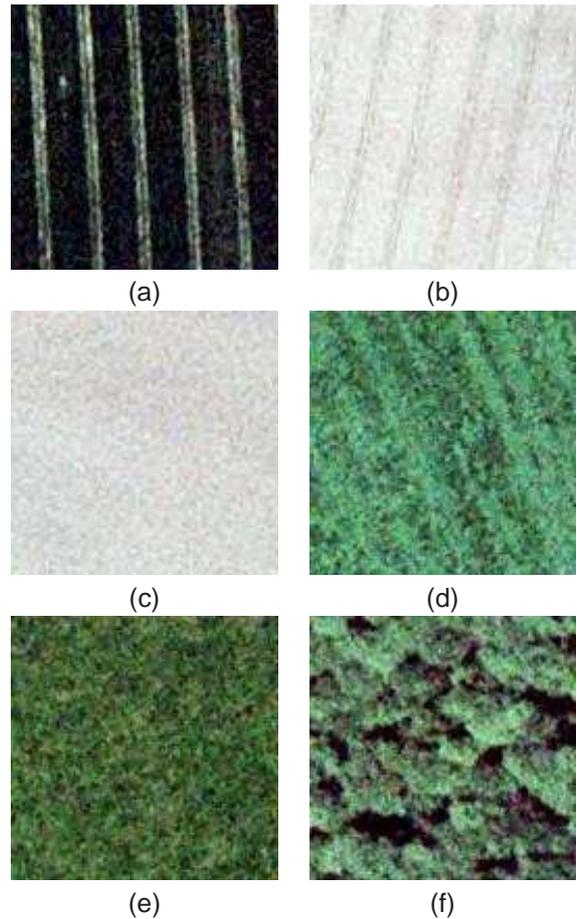


FIG. 6 – Présentation des 6 classes de texture. (a) : blé ; (b) : maïs traité ; (c) : maïs ; (d) : prairie semée ; (e) : prairie ; (f) : forêt

dement puis se stabilise à environ 6 %. Il convient alors de limiter notre arbre à 20 nœuds afin de maintenir une rapidité d'exécution. Comme les 2 classifications l'ont prouvé sur la figure 7, ce nombre de nœuds correspond à un bon compromis entre le taux d'erreur et le temps de calcul.

L'arbre de décision à 20 nœuds met en évidence les indicateurs les plus discriminants sur la figure 8. Parmi eux, l'erreur moyenne (représentée par  $M. KLD$ ) permet de distinguer les changements abrupts des changements les plus subtils comme le passage d'une prairie à une prairie semée. L'indicateur  $Std. d.D$ , qui correspond à l'écart-type des dissimilarités entre les différents niveaux d'échelle pour les détails diagonaux permet de discriminer principalement les changements à grande échelle, de type orienté  $\leftrightarrow$  homogène (comme les passages d'un maïs traité ou une forêt à une prairie).

Les changements orientés sont correctement discriminés à partir du degré d'isotropie attribué par l'étape de réorientation des objets (indicateur  $Iso. bloc1$  sur l'arbre). En ce qui concerne les changements orientés plus subtils, on remarque qu'ils sont notamment détectés à partir de l'indicateur  $Std Niv.4$  qui correspond à l'écart-type des dissimilarités mesurées dans les composantes du niveau 4

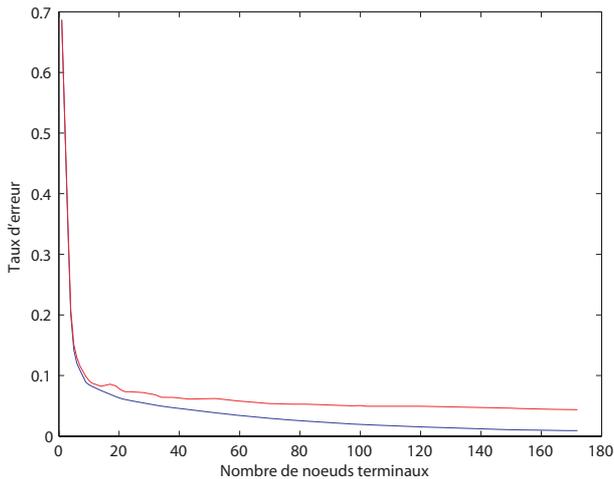


FIG. 7 – Evolution du taux d'erreur de la classification par arbres de décision. En bleu : taux d'erreur de la classification élaborée à partir de l'ensemble des tests ; en rouge, le taux d'erreur de la classification élaborée à partir de 30 % des tests

d'échelle. Cela s'explique par la composante verticale (correspondant à l'axe d'orientation des motifs dans le cas de textures orientées) qui mesure de très fortes dissimilarités dans ce niveau contrairement aux autres composantes du même niveau (Figure 5).

## 6 Conclusion

Dans cet article nous avons proposé une mesure de détection de changement adaptée aux images de télédétection à THRS. Cette mesure repose sur la comparaison des différentes textures contenues dans les objets, par le biais des différences entre les distributions des coefficients issus d'une décomposition en ondelettes des objets initiaux. Une étape préliminaire de réorientation des images nous permet d'être moins sensible à la rotation. Le vecteur décrivant le changement retenu est une combinaison des différences entre distributions à chaque niveau de la décomposition des images.

Nous avons validé notre mesure en effectuant des classifications, par arbres de décisions, de différents types de changements apparaissant dans des parcelles agricoles sur des photographies aériennes.

Les perspectives de ce travail consistent à appliquer cette méthode sur d'autres types de textures (en milieu urbain notamment) et d'autres données de type THRS. Nous envisageons également de coupler cette métrique avec une méthode de segmentation afin d'obtenir un outil de détection de changement qui évalue à la fois les changements forme et de contenu des objets étudiés.

## Références

[1] J.F. Aujol, G. Aubert, and L. Blanc-Faud. Wavelet-based level set evolution for classification of textured images. *IEEE Trans. Image Processing*, 12(12):1634–1641, 2003.

[2] L. Breiman, J. Friedman, R. Olshen, and C. Stone. *Classification and Regression Trees*. Wadsworth and Brooks, Monterey, CA, 1984.

[3] P. Coppin, I. Jonckheere, and E. Lambin. Digital change detection methods in ecosystem monitoring : A review. *International Journal of Remote Sensing*, 25 :1565–1596, 2004.

[4] G. Cross and A. Jain. Markov random field texture models. *IEEE Trans. Pattern Anal. Machine Intell.*, 5 :25–39, 1983.

[5] M. Do and M. Vetterli. Wavelet-based texture retrieval using generalized gaussian density and kullback-leibler distance. *IEEE Trans. Image Processing*, 11(2) :146–158, 2002.

[6] W.T. Freeman and E.H. Adelson. The design and use of steerable filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(9) :891–906, 1991.

[7] M. A. Friedl and C. E. Brodley. Decision tree classification of land cover from remotely sensed data. *Remote sensing of environment*, 61 :399–409, 1997.

[8] C. Germain, J.P. Da Costa, O. Laviolle, and P. Baylou. Multiscale estimation of vector field anisotropy. application to texture characterization. *Signal Processing*, 83 :1487–1503, 2003.

[9] R.M. Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 5 :786–804, 1979.

[10] B. Josso, D.R. Burton, and M.K. Lalor. Texture orientation and anisotropy calculation by fourier transform and principal component analysis. *Mechanical Systems and Signal Processing*, 19 :1152–1161, 2005.

[11] A. Laine and J. Fan. Texture classification by wavelet packet signatures. *IEEE Trans. Pattern Anal. Mach. Intell.*, 15(11) :1186–1191, 1993.

[12] D. Lu, P. Mausel, E. Brondizio, and E. Moran. Change detection techniques. *International Journal of Remote Sensing*, 25 :2365–2407, 2004.

[13] B. Luo, J.-F. Aujol, Y. Gousseau, and S. Ladjal. Indexing of satellite images with different resolutions by wavelet features. *IEEE Trans. on Image Processing*, 17(8) :1465–1472, 2008.

[14] S.G. Mallat. *A wavelet tour of signal processing*. Academic Press, 1998.

[15] A. Materka, M. Strzelecki, Texture Analysis, Methods A Review, Andrzej Materka, and Michal Strzelecki. Texture analysis methods - a review. Technical report, Institute of Electronics, Technical University of Lodz, 1998.

[16] T. Randen and J.H. Husoy. Filtering for texture classification : A comparative study. *IEEE Trans. Pattern Anal. Machine Intell.*, 21(4) :291–310, April 1999.

[17] T.R. Reed and J.M.H. du Buf. A review of recent texture segmentation and feature extraction techniques. *CVGIP : Image Understanding*, 57 :359–372, 1993.

[18] S. R. Safavian and D. Landgrebe. A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man and Cybernetics*, 21 :660–674, 1991.

[19] P. Scheunders, S. Livens, G. van de Wouwer, P. Vautrot, and D. Van Dyck. Wavelet-based texture analysis. *Journal of Computer Science and Information Management, Special issue on Image Processing*, 1998.

[20] M. Tuceryan and A.K. Jain. *The Handbook of Pattern Recognition and Computer Vision (2nd Edition)*, chapter Texture Analysis, pages 207–248. C.H. Chen, L.F. Pau (P.S.P Wang Eds), 1998.

[21] M. Unser. Texture classification and segmentation using wavelet frames. *IEEE Trans. Image Processing*, 4(11) :1549–1560, 1995.

[22] M.K. Varansi and B. Aazhang. Parametric generalized gaussian density estimation. *J. Acoust. Soc. Amer.*, 86 :1404–1415, 1989.

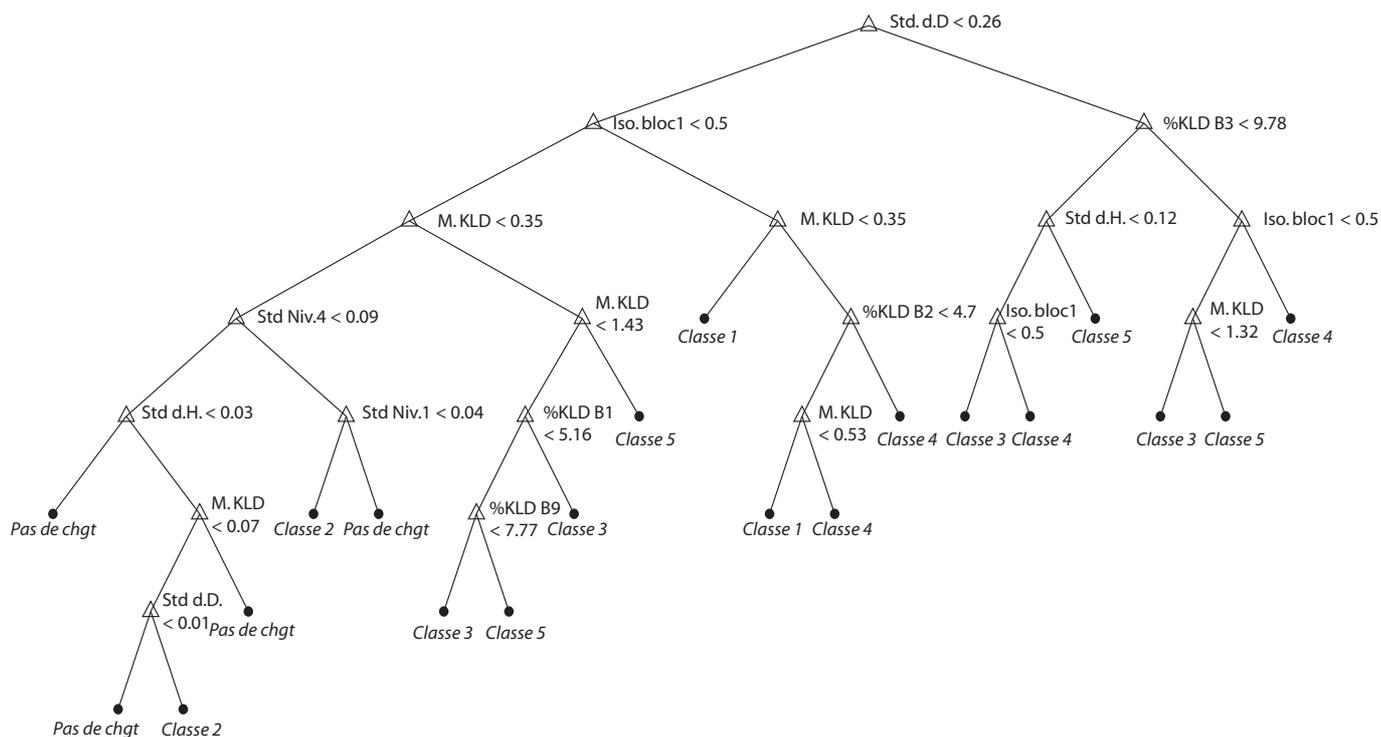


FIG. 8 – **Arbre de décision avec 20 noeuds terminaux.** Classe 1 : changement à grande échelle, abrupt et orienté ; Classe 2 : changement à grande échelle, subtil et orienté ; Classe 3 : changement entre deux textures homogènes à la même échelle ; Classe 4 : changement à grande et petite échelle, abrupt et orienté ; Classe 5 : changement à grande échelle entre deux textures homogènes ; M. KLD : moyenne de l'ensemble des *KLS* ; Iso. bloc1 : label de texture orientée attribué l'étape de ré-orientation ; Std. d.H. : écart-type des dissimilarités entre les différents niveaux d'échelle pour les détails horizontaux ; Std. d.D. : écart-type des dissimilarités entre les différents niveaux d'échelle pour les détails diagonaux ; Std. Niv.1 : écart-type des dissimilarités mesurées dans les composantes du premier niveau ; Std. Niv.4 : écart-type des dissimilarités mesurées dans les composantes du quatrième niveau ; %KLD B1 : rapport entre la dissimilarité de la composante horizontale du premier niveau par la somme totale des dissimilarités ; %KLD B2 : rapport entre la dissimilarité de la composante verticale du premier niveau par la somme totale des dissimilarités ; %KLD B3 : rapport entre la dissimilarité de la composante diagonale du premier niveau par la somme totale des dissimilarités ; %KLD B9 : rapport entre la dissimilarité de la composante diagonale du troisième niveau par la somme totale des dissimilarités