
Détection de changements structurels sur des images satellite haute résolution

Application en milieu forestier

Samia Boukir¹, Camille Orny^{1,2}, Nesrine Chehata^{1,3},
Dominique Guyon², Jean-Pierre Wigneron²

1. Laboratoire G&E (EA 4592), IPB / Université de Bordeaux,
1 allée F. Daguin, 33607 Pessac Cedex, France
prénom.nom@ipb.fr

2. INRA - UMR 1391 ISPA, 33140 Villenave d'Ornon, France
prénom.nom@bordeaux.inra.fr

3. LISAH UMR 144, IRD, T-1004 El Menzah, Tunis, Tunisie

RÉSUMÉ. Les changements environnementaux brutaux et massifs, qui affectent généralement de grandes surfaces, doivent être localisés le plus rapidement possible pour gérer l'impact immédiat de ce type d'évènements sur les écosystèmes et prévenir les risques associés. Il est donc nécessaire de développer des méthodes permettant d'établir efficacement une carte des changements. Dans cette optique, une approche région quasi non supervisée de détection de changements sur des images satellite à haute résolution spatiale est proposée. Un procédé innovant de sélection automatique d'attributs, inspiré des procédures de calibrage, optimise la segmentation et la classification. Un nouveau descripteur spatio-temporel, basé sur le taux de fragmentation des régions détectées, permet alors de réaliser une classification binaire des changements en zones intactes et altérées. Cette méthode passe par des étapes de segmentation et de classification mean shift. L'approche a été évaluée en milieu forestier sur un couple d'images satellite multispectrales Formosat-2 acquises avant et après une tempête majeure pour reconnaître et cartographier les dégâts.

ABSTRACT. Brutal and massive environmental changes, generally affecting large areas, have to be localized as rapidly as possible in order to manage the immediate impact of this type of events on ecosystems and prevent related risks. Therefore, it is necessary

to develop efficient methods for change mapping. A quasi-unsupervised region-based method for change detection in high resolution satellite images is proposed. An automatic feature selection optimizes image segmentation and classification via an original calibration-like procedure. A binary classification enables then to separate altered from intact areas thanks to a new spatio-temporal descriptor based on the level of fragmentation of obtained regions. Both segmentation and classification involve a mean shift procedure. The method was assessed on forest environment using a Formosat-2 multispectral satellite image pair acquired before and after a major storm to identify and map the damages.

MOTS-CLÉS : cartographie, classification de régions, détection de changements, image multispectrale, segmentation, sélection d'attributs.

KEYWORDS: mapping, region classification, change detection, multispectral image, segmentation, feature selection.

DOI:10.3166/TS.30.401-429 © 2013 Lavoisier

Extended abstract

Environmental changes can be continuous and progressive (forest decay, drought, etc.) or, on the contrary, brutal and massive, caused by natural disasters (storm, fire, flood, etc.). This work presents a method for detecting brutal structural changes, hence between two dates, using satellite images acquired before and after the accidental event. In order to manage the immediate impact of this type of events on ecosystems and prevent related risks, a rapid change mapping has to be carried out. Hence, we have chosen a quasi-unsupervised approach, which is much more practical than a machine learning-based alternative. Indeed, the latter requires field data that are costly and time consuming, especially in a remote sensing context. Our method is a multi-temporal region-based approach. It relies on the *mean shift* algorithm for both the segmentation and the classification steps. It provides two main novelties:

- an automated feature selection via a calibration-like procedure, and
- a new spatio-temporal descriptor based on the level of fragmentation of obtained regions.

The *mean-shift* algorithm is a non parametric density-based method for the analysis of complex multi-mode feature space and for the delineation of arbitrarily shaped clusters. This powerful clustering algorithm has been successfully used for both the classification and the segmentation of gray scale and color images during the last decade. However, very little work has been reported regarding the performance of this technique on remotely sensed data.

Our feature selection method provides both the most relevant features for the segmentation of a multispectral image and the associated optimal parameters setting. It is quasi-unsupervised as it relies on *test frames* that use only

a few samples of small homogeneous areas of the image. The first step of this calibration-like technique is the creation of a test frame per feature containing regions belonging to different classes to identify. These test frames are then individually segmented (mono-feature) or by combining them (multi-features, normalized) with different parameters settings of the segmentation algorithm. The obtained optimal parameters setting will be then exported to the entire image. The best features for the segmentation of the test frames will also be used for the segmentation of the whole image. Though this procedure is sub-optimal, it provides a good compromise between the quality and the complexity of the segmentation process. Besides, in the context of remote sensing, this technique is an interesting alternative to face the lack of training data which are required in large amounts in supervised methods. Three types of features are assessed in our feature selection method: spectral, textural and temporal. The considered textural features are the well-known Haralick's features, based on the computation of co-occurrence matrices, which are also the most commonly used in remote sensing thanks to their relevance and simple implementation.

A multi-temporal region-based change detection method, relying on the *mean shift* algorithm, is introduced. It aims at producing a change mapping with a minimum of training data, hence induced by a quasi-unsupervised classification process. The regions are first delineated by feature selection-based *mean shift* segmentation and then, the spectral, textural and temporal features of the obtained regions are calculated by averaging the features on each region. The regions are then classified using again the *mean shift* procedure but exclusively in the feature space, as opposed to the traditional use of the *mean shift* which also includes the spatial information, in other words, the joint spatial/radiometric and not only radiometric space.

Similar to the segmentation process, the classification task is optimized via the introduced feature selection method using both mono and multi-features test frames. The latter are created in concordance with the change detection application.

The separation of the numerous change classes produced by the multispectral *mean shift* classifier into two classes, *change/no-change*, is carried out using a novel spatio-temporal descriptor: the fragmentation rate. Indeed, the complexity of a landscape increases over time, tending to a more diversified and more fragmented landscape. This phenomenon reflects on the perceived image as heterogeneous regions. The presence of heterogeneity in an initially homogeneous area would be then likely due to a change. The fragmentation rate is calculated through the comparison between the image segmentations, before and after change, and characterizes the level of fragmentation of the regions before change. This fragmentation rate is then averaged per change class. The resulting fragmentation rate image is then classified into two classes, *change/no-change*, using the unsupervised thresholding technique of Otsu. This method

minimizes the intra-class variance, assuming a separation into two Gaussian classes.

The whole change detection scheme was assessed on forest environment using a Formosat-2 multispectral satellite image pair acquired before and after a major storm to identify and map the damages. It led to an accurate localization of the most affected forest areas, at high resolution. The obtained overall accuracy (87.8 %) outperforms a traditional pixel-based approach without a feature selection step by about 10 %. To assess the relevance of the proposed feature selection method, the segmentation was carried out using all the available multispectral bands (8 bands). The resulting change mapping accuracy was then 83.8 %, hence a loss of accuracy of 4 % with respect to our feature-selection based performance. The most relevant features, provided by the feature selection method, for the segmentation of both before and after storm images, are the ones related to the red band, a consistent result with respect to thematic knowledge. The textural features are not among the best selected features due to the used spatial resolution (8 m) which is probably not high enough to properly capture the textural information.

1. Introduction

La mise à jour de cartographies de territoires, en constante évolution, est une tâche fastidieuse, en particulier s'il s'agit de sites urbains complexes et en explosion démographique. Actuellement, la méthode de mise à jour de cartographies de l'occupation du sol la plus utilisée reste la photo-interprétation (Clandillon *et al.*, 2003). Certes, la capacité d'interprétation humaine est puissante, surtout si l'interprète a une bonne connaissance du site. Néanmoins, c'est une tâche lourde, sujette à des erreurs d'omission et à la subjectivité de l'interprète. L'imagerie satellite offre un moyen efficace et rentable pour détecter et identifier les changements de sites géographiques étendus (Lunetta *et al.*, 2004). En outre, la disponibilité de données de télédétection est garantie pour les décennies à venir, faisant des satellites des instruments puissants de détection de changements à long terme.

Beaucoup de techniques de détection de changements ont été explorées pour les moyenne et haute résolutions spatiales (Coppin *et al.*, 2004). Deux principales approches existent (Pacifi *et al.*, 2007) : non supervisée et supervisée. Bien que la seconde approche requière la disponibilité de données d'apprentissage, souvent via une tâche délicate et coûteuse, elle est plus robuste aux conditions atmosphériques et d'éclairement aux 2 dates d'acquisition, avant et après changement, et a la capacité d'identifier explicitement le type de changements des surfaces observées.

Les méthodes non supervisées sont généralement basées sur la comparaison de données multi-temporelles brutes, typiquement une différence d'images suivie d'un seuillage (Coppin *et al.*, 2004; Bruzzone, Prieto, 2000). Les méthodes

non supervisées sont applicables à la détection de changements (ex. déforestation) mais sont pour la plupart inappropriées lorsqu'il s'agit de caractériser ces changements (ex. étalement urbain ou rotation des cultures).

Le classifieur supervisé recherche des classes de changement pour lesquelles il aura été entraîné auparavant (Im, Jensen, 2005). Les réseaux de neurones (Pacifi *et al.*, 2007) et les séparateurs à valorisation de marge (*Support Vector Machines* ou *SVMs*) (Melgani, Bruzzone, 2004) comptent parmi les classifieurs supervisés les plus populaires, en particulier dans la communauté de télédétection. La popularité grandissante des *SVM* est due notamment à leur capacité d'analyse d'espaces de caractéristiques de grande dimension (données hyperspectrales) avec un nombre relativement limité de données d'apprentissage.

La classification d'images multi-temporelles est l'approche à privilégier pour produire une typologie fine des changements. L'approche la plus simple est la post-classification qui consiste à comparer les cartographies obtenues en classifiant indépendamment deux images satellite du même site, acquises à deux dates différentes (Coppin *et al.*, 2004; Fuller *et al.*, 2003; Nielsen *et al.*, 1998). L'avantage de cette approche est qu'elle ne nécessite pas de normalisation vis-à-vis des conditions atmosphériques entre les deux acquisitions. Néanmoins, la qualité de la carte de changements finale dépend de la précision des deux processus de classification sous-jacents (Kennedy *et al.*, 2009). La classification multi-temporelle (ou classification conjointe) permet d'y remédier en associant à chaque pixel un vecteur intégrant les descripteurs issus des deux images multi-dates (Conchedda *et al.*, 2008; Schwarz *et al.*, 2001). Cette approche est certes plus complexe que la précédente puisqu'elle implique un descripteur de taille plus importante, un risque plus élevé de redondance d'attributs et souvent, un nombre plus important de classes. Toujours est-il que l'utilisation implicite de la dépendance temporelle des données améliore indéniablement la performance des algorithmes d'analyse des changements bi-dates (Coppin *et al.*, 2004).

Les approches de détection de changement commencent à intégrer de l'information contextuelle sur les données acquises (Conchedda *et al.*, 2008; Mallinis *et al.*, 2008; Desclée *et al.*, 2006). Il s'agit d'identifier des régions relativement homogènes comme par exemple des zones de végétation (jardins, plantations, forêts, etc.) en milieu urbain. La détection de changements standard, qui se base sur les propriétés de pixels individuels, doit alors s'étendre à l'analyse de régions caractérisées non seulement par leurs propriétés spectrales, mais aussi par leur forme, contour, texture, ou topologie. On s'oriente alors vers une analyse plus sophistiquée d'objets multi-temporels mais intuitivement plus faciles à interpréter. La classification basée région requiert néanmoins, contrairement à l'approche élémentaire basée pixel, la connaissance *a priori* du type d'objets recherchés (ex. arbre pour le milieu forestier) (Blaschke, 2010). Certains travaux utilisent des approches intermédiaires s'appuyant sur des descripteurs de régions par pixel avant une classification basée pixel (Im, Jensen, 2005).

L'extraction de régions pertinentes pour la détection de changements passe par un processus de segmentation d'images. Beaucoup de travaux ont été consacrés dans la littérature à la segmentation d'images en niveaux de gris et en couleur (Cheng *et al.*, 2001). Dans le cas de la détection de changements, l'algorithme de segmentation peut être appliqué à toutes les bandes spectrales multi-temporelles pour extraire des régions spectralement et temporellement similaires (Conchedda *et al.*, 2008; Desclée *et al.*, 2006). Les régions extraites peuvent alors être classifiées comme zones de changement ou non, ou selon un schéma de caractérisation des changements plus complexe. Outre la richesse sémantique des régions par rapport aux pixels bruts, l'approche région permet d'atténuer le bruit de granulation (poivre & sel) et les effets d'ombrage des images satellite (Johansen *et al.*, 2010), et d'accélérer le processus de classification en réduisant de façon très significative le nombre d'instances à classifier. En outre, elle est plus robuste aux erreurs de recalage des images qui sont d'autant plus importantes que la résolution est haute. La principale limitation des approches région est la délimitation des frontières des objets, souvent délicate. Cela explique en partie pourquoi les approches région rapportées dans la littérature ne produisent pas toujours des cartographies plus précises que les approches pixel.

Les changements environnementaux peuvent être continus et progressifs (déperissement en forêt, sécheresse, etc.) ou, au contraire, brutaux et massifs, causés par des catastrophes naturelles (tempête, feu, inondation, etc.). Ce travail présente une méthode de détection de changements structuraux brutaux et donc entre deux dates, à partir d'images satellitaires acquises avant et après l'évènement causal. Pour permettre une cartographie d'urgence nécessaire à la gestion de ce type de changements et à la prévention des risques associés, notre choix s'est porté sur une approche quasi non supervisée, beaucoup moins lourde à mettre en œuvre qu'une technique d'apprentissage automatique. En effet, celle-ci requière des données de terrain *in situ* coûteuses et longues à obtenir, particulièrement dans un contexte de télédétection. Notre méthode est multi-temporelle et basée région. Elle fait appel à l'algorithme du *mean shift* (Fukunaga, Hostetler, 1975) aussi bien pour la segmentation que pour la classification. Elle apporte deux principales originalités :

- la sélection automatique d'attributs par une technique inspirée des procédures de calibrage de caméras,
- l'intégration d'un nouvel indice spatio-temporel dans le processus de détection de changements.

Cet article est organisé comme suit. La section suivante décrit le contexte et la principale application de ce travail. La section 3 détaille l'algorithme du *mean shift* utilisé pour la segmentation et la classification. Notre technique de sélection automatique d'attributs optimisant ces deux étapes est alors introduite en section 4. La section 5 décrit notre méthode de détection de changements structuraux de type accidentel. Une analyse de la complexité algorithmique de notre

approche fait l'objet de la section suivante. La section 7 présente la validation de notre méthode sur les données disponibles, suivie d'une conclusion.

2. Application visée

Les tempêtes constituent les perturbations les plus importantes des forêts européennes et sont responsables de plus de la moitié des dégâts de forêts observés durant la seconde moitié du 20^e siècle. L'exceptionnelle tempête *Klaus* (24 janvier 2009) a affecté près d'un quart de la surface de la forêt de pin exploitée dans le sud-ouest de la France qui couvre près d'un million d'hectares.

Les dégâts de tempête doivent être inventoriés le plus rapidement possible pour prévenir la prolifération des ravageurs et les risques d'incendie. Il est donc nécessaire de localiser rapidement les dégâts. L'étendue des dégâts est très grande et l'imagerie satellite représente une solution optimale pour leur surveillance rapide. Celle-ci a néanmoins été peu utilisée pour la cartographie des dégâts de tempête en forêt. La détection de changements forestiers brutaux par imagerie satellitaire concerne principalement les défoliations massives (Olthof *et al.*, 2004) et les coupes rases (Fraser *et al.*, 2005; Desclée *et al.*, 2006; Huang *et al.*, 2008; Liu *et al.*, 2008; Conchedda *et al.*, 2008). Rares sont les travaux traitant de changements structurels plus complexes tels que les dégâts de tempête (King *et al.*, 2005; Clandillon *et al.*, 2003; Meyer *et al.*, 2001; Schwarz *et al.*, 2001). De plus, les cartographies existantes ont généralement été produites à une résolution relativement grossière, de l'ordre de l'hectare ou plus.

Récemment, des approches région ont été développées pour la détection de changements en milieu forestier (Chehata *et al.*, 2011; Conchedda *et al.*, 2008). Cette étude présente une approche région pour la classification multi-temporelle et quasi non supervisée des dégâts de tempête, testée avec un couple d'images multispectrales Formosat-2 (4 bandes spectrales : bleu, vert, rouge et Proche Infra Rouge (PIR)) à haute résolution spatiale (8 m), acquises juste avant et après la tempête *Klaus*. Cette résolution de 8 m représente approximativement le diamètre maximal d'une couronne de pin maritime. Donc 1 pixel contient un à plusieurs arbres selon leurs dimensions.

A notre connaissance, toutes les méthodes existantes de détection de dégâts de forêt sont supervisées (Schwarz *et al.*, 2001). Des méthodes non supervisées ont été utilisées pour la détection de défoliation uniquement (Franklin *et al.*, 1995) et de coupes rases (Desclée *et al.*, 2006). En outre, l'algorithme du *mean shift*, à la base de notre approche de détection de changements (Boukir *et al.*, 2011; Chehata *et al.*, 2011), a été peu mis en œuvre pour des travaux de cartographie forestière. Des travaux relatifs sont certes apparus récemment (Boukir *et al.*, 2012; Taud *et al.*, 2012) mais ils concernent des approches pixel et non région comme notre méthode qui implique le *mean shift* à deux niveaux : segmentation puis cartographie. Les performances de cet algorithme puissant sur des images de forêt, aussi bien dans un contexte de segmentation que de classification multispectrale, seront analysées dans la section 7.

3. Segmentation

3.1. *Exploitation de l'information spatiale en télédétection*

La plupart des méthodes récentes de cartographie exploitent l'information spatiale de deux façons principalement. La première consiste à calculer des descripteurs régionaux (calculés sur le voisinage de chaque pixel) avant une classification pixel à pixel (Im, Jensen, 2005; Fraser *et al.*, 2005). La seconde passe par un processus de segmentation d'images (Gonzales, Woods, 2008) précédant une classification basée région. Dans (Im, Jensen, 2005) par exemple, un indice de corrélation bi-temporel, calculé sur un petit voisinage, est exploité pour une classification binaire supervisée en *changement/non changement*, en milieu urbain. Dans (Makela, Pekkarinen, 2001), il est rapporté que la masse de bois est mieux modélisée par des descripteurs calculés sur des régions délimitées par segmentation que ceux calculés sur un voisinage fixe. D'autres auteurs ont utilisé l'information de texture pour améliorer la classification pixel à pixel (Ruiz *et al.*, 2004; Mallinis *et al.*, 2008).

La majorité des méthodes basées région existantes en télédétection utilisent l'algorithme de segmentation classique par croissance de régions (Conchedda *et al.*, 2008; Johansen *et al.*, 2007). Cet algorithme agrège les pixels adjacents tant qu'un critère d'homogénéité, basé sur la variance intra-objet, est vérifié (Gonzales, Woods, 2008). Cependant, les images à haute et très haute résolution comprennent des pixels distincts très contrastés comme ceux constitués exclusivement par les ombres et les zones éclairées. De ce fait, les algorithmes basés sur des mesures d'homogénéité ne sont pas les plus adaptés en télédétection.

La segmentation *mean shift* (Comaniciu, Meer, 2002), non paramétrique par essence, ne fait pas intervenir explicitement de mesure d'homogénéité, contrairement à l'algorithme de segmentation par croissance de régions, elle est donc *a priori* moins problématique sur les images de télédétection qui sont généralement texturées et contrastées. Cet algorithme efficace est à la base de notre technique de détection de changements.

3.2. *Segmentation mean shift*

La procédure d'optimisation *mean shift* a été initialement proposée par Fukunaga et Hostetler (1975) puis adaptée par Comaniciu et Meer pour le partitionnement (ou *clustering*) et la segmentation d'images (Comaniciu, Meer, 2002). L'algorithme *mean shift* est une méthode non paramétrique d'analyse d'espaces de caractéristiques complexes et multi-modes, et pour la délimitation de partitions (ou *clusters*) de forme quelconque. Cette approche robuste a été utilisée avec succès pour la classification et la segmentation d'images de niveaux de gris et couleur durant la dernière décennie. Cependant, très peu de travaux ont été rapportés dans la littérature sur la performance de cette technique en télédétection (Bo *et al.*, 2009; Wang *et al.*, 2006).

L'algorithme *mean shift* regroupe les pixels en les associant à un mode local estimé, c'est-à-dire à un pic de densité dans l'histogramme local (Comaniciu, Meer, 2002). Cette méthode explore la fonction de densité de probabilité du ou des attributs considérés dans un voisinage local utilisant conjointement l'information spatiale et radiométrique. Les deux seuls paramètres utilisés sont les résolutions spatiale h_s et radiométrique h_r de la segmentation correspondant aux dimensions spatiale et radiométrique du voisinage. La recherche des modes locaux des pixels s'effectue dans l'espace conjoint des attributs et du domaine spatial à $n+2$ dimensions où n est le nombre d'attributs considérés. Ces modes sont localisés sans estimer la densité globale qui représente une tâche rédhitive en termes de temps de calcul. Elle est basée sur le décalage récursif de fenêtres de dimension $(n+2)$ vers des modes locaux de la densité des pixels. Ces fenêtres sont centrées en des points initialement choisis de façon aléatoire dans l'image. Ces points sont alors décalés itérativement vers la moyenne de leur voisinage local. Une fois que la localisation du mode est déterminée, la région (ou *cluster*) associée à ce mode est délimitée en fonction de la structure locale de l'espace des attributs (Comaniciu, Meer, 2002). Dans un espace à attributs multiples, la segmentation passe par une normalisation préalable des attributs utilisés.

Les résolutions spatiale h_s et radiométrique h_r peuvent être déduites de la taille des objets recherchés et de leurs propriétés radiométriques. Afin d'extraire une région de l'image, h_r doit être à la fois :

- supérieur à la différence radiométrique maximale entre 2 pixels de la région,
- inférieur à la différence radiométrique entre les pixels de la région et les pixels voisins de la région.

En même temps, h_s doit être proche de la taille des objets recherchés. En effet, la fenêtre glissante de recherche des modes doit rester spatialement à l'intérieur de la région afin d'associer ses pixels à un mode localisé à l'intérieur de la région.

4. Sélection automatique d'attributs

4.1. Travaux relatifs

Dans la littérature, la segmentation multispectrale précédant la classification basée région est souvent réalisée sur l'ensemble des bandes disponibles de l'image (Makela, Pekkarinen, 2001; Mallinis *et al.*, 2008). Certains travaux proposent une sélection automatique d'attributs. Dans (Trias-Sanz *et al.*, 2008), l'objectif de l'étude est de déterminer les attributs les mieux adaptés aux zones rurales, parmi les descripteurs de texture et les composantes couleur de la transformation intensité-teinte-saturation. La sélection supervisée d'attributs pour la classification est parfois effectuée en intégrant des résultats de modélisa-

tion de variables environnementales. Dans (Olthof *et al.*, 2004) et (King *et al.*, 2005), par exemple, les attributs de l'image les mieux corrélés au pourcentage de dommage de la couronne d'arbre sont utilisés pour la classification de dégâts en forêt.

4.2. Sélection automatique d'attributs via une mire

Une méthode générique de sélection des attributs les plus pertinents pour la segmentation d'une image multispectrale, inspirée du calibrage de caméras, est proposée. Cette méthode permet de définir aussi le paramétrage optimal de la segmentation. Elle est quasi non supervisée puisque la construction de mires ne requiert que quelques petites zones homogènes renseignées de l'image. La première étape de cette méthode est la construction (automatisée) d'une mire par attribut contenant des régions appartenant aux différentes classes à identifier. Bien évidemment, ces zones sont différentes de celles utilisées pour l'évaluation de la carte produite pour assurer une évaluation finale indépendante de la méthode élaborée. Ces mires sont ensuite segmentées individuellement (mono-attribut) et en les combinant (multi-attributs, normalisés) avec différents paramétrages de l'algorithme de segmentation. Le paramétrage optimal obtenu sera alors exporté à l'ensemble de l'image. De même, le ou les attributs les plus pertinents pour la segmentation des mires seront retenus pour segmenter l'image entière. Certes, ce procédé est réducteur et sous-optimal mais il constitue un bon compromis qualité/complexité du processus de segmentation. En outre, dans le contexte de télédétection en particulier où les mesures de terrain sont rares et coûteuses, cette technique permet de pallier au manque de données d'apprentissage dont sont gourmands les processus supervisés. Le résultat de segmentation des attributs est évalué par un indice de performance normalisé PS (Performance de Segmentation), à maximiser, défini ainsi :

$$PS = \frac{1}{n_c} \sum_i \frac{\max_j [A(R_i) \cap A(R_{S_j})]}{A(R_i)} \text{ avec } R_i \cap R_{S_j} \neq \emptyset \quad (1)$$

où A est l'aire, n_c le nombre réel de classes dans la mire construite, R_i les régions réelles et R_{S_j} les régions segmentées, partiellement ou entièrement superposées sur les régions réelles. La performance dépend du taux de recouvrement des régions.

Les attributs considérés sont spectraux, texturaux et temporels. Les attributs spectraux correspondent aux réflectances des deux images dans les domaines du bleu, du vert, du rouge et du proche infrarouge, ainsi que deux indices de végétation qui sont des combinaisons non linéaires des réflectances Rouge et PIR : indice de différence normalisée ou NDVI (*Normalized Difference Vegetation Index*) et indice de végétation ajusté pour le sol ou SAVI (*Soil Adjusted Vegetation Index*). Des statistiques du 1^{er} ordre telles que la moyenne et la variance de réflectance sont également utilisées. Les attributs de texture considérés sont les indices d'Haralick (Haralick *et al.*, 1973), les plus communs

en télédétection car offrant un bon compromis entre simplicité de mise en œuvre et pertinence (St-Louis *et al.*, 2006; Ruiz *et al.*, 2004; Tuominen, Pekkarinen, 2005). Trois attributs temporels classiques, la corrélation, la différence et le ratio entre les deux images, sont déterminés pour chaque domaine spectral. Nous avons choisi d'exploiter tant des ratios que des différences car nous avons opté pour une approche systématique, sans *a priori*, aussi bien au niveau attribut qu'au niveau paramétrage (résolution radiométrique h_r). Ainsi, bien que les ratios seraient *a priori* moins judicieux que les différences (rapport signal/bruit moins favorable), ils s'avèrent plus performants pour la segmentation de l'image après-tempête, comme le montrent nos résultats expérimentaux (tableau 2). Il faut souligner cependant que les résolutions radiométriques h_r associées sont importantes, permettant ainsi de lisser le bruit.

5. Détection de changements non supervisée et basée région

Une méthode de classification multi-temporelle et basée région, qui s'appuie sur l'algorithme du *mean shift* est introduite. Il s'agit d'élaborer une cartographie à partir d'un minimum de données d'apprentissage, issue donc d'un processus de classification quasi non supervisé. Bien que cette approche fournisse des classes de changements fines et multiples, l'objectif à court terme de ce travail a été restreint à la production d'une carte de changements binaire. En effet, aucune donnée de référence sur les types de changement n'est disponible pour l'application visée. Cependant, les choix algorithmiques sous-jacents restent compatibles avec la finalité à plus long terme visant la caractérisation plus fine des changements observés, qui sera validée dans des travaux futurs.

Certaines méthodes de détection de changements basées région appliquent la segmentation simultanément à l'ensemble des bandes des images multispectrales avant et après changement pour délimiter les régions dont l'évolution temporelle est homogène (Conchedda *et al.*, 2008; Desclée *et al.*, 2006). Notre approche segmente aussi conjointement les différentes bandes des deux images multispectrales multi-temporelles. Néanmoins, elle sélectionne auparavant les attributs les plus pertinents pour la détection de changements, contrairement aux approches classiques qui utilisent systématiquement toute l'information disponible. Cette approche systématique n'est pas forcément la plus performante car la même importance est attribuée à chaque bande alors qu'elles peuvent avoir un impact significativement différent sur le processus de classification. Il est bien connu par exemple que la bande bleue est affectée par la diffusion de Rayleigh (Richards, Jia, 1999). Cette bande bruitée ne porte à priori pas l'information spectrale la plus pertinente pour la segmentation ou la classification, comme pourront le confirmer nos résultats expérimentaux.

5.1. Classification multispectrale *mean shift*

Dans notre approche, les régions sont d'abord délimitées par la segmentation *mean shift* puis, les attributs, de type spectral, textural ou temporel,

des régions obtenues, sont calculés par moyennage sur chaque région. Les régions sont ensuite classifiées en utilisant le principe du *mean shift* mais en ne considérant que l'espace des caractéristiques des objets, contrairement à l'algorithme du *mean shift* initial qui exploite aussi l'information spatiale, soit l'espace joint spatial/radiométrique et non uniquement radiométrique (Comaniciu, Meer, 2002).

Comme pour le processus de segmentation, la classification est optimisée par une phase préalable de sélection automatique d'attributs via des mires mono ou multi-attributs. Les mires considérées sont en adéquation avec l'application de détection de changements. Elles sont construites à partir de deux échantillons uniquement (changement/non changement) décrits exclusivement par des attributs temporels.

Le classifieur produit un nombre spontané de classes qui dépend de la distribution des attributs et de la résolution spectrale h_r . Plus h_r est élevé, plus le nombre de classes produites sera faible. Dans le contexte de détection et caractérisation fine de changements, le nombre de classes de changement produites a tendance à être élevé. Ce problème de fragmentation est récurrent dans les processus de segmentation et de classification et est accentué sur les images d'environnements naturels qui exhibent des structures de forte complexité. De plus, certaines zones sont peu contrastées et ne facilitent pas la séparation binaire en classes de *changement/non changement*, notamment les zones de changement partiel dans les transitions *changé/inchangé*. Ce phénomène a inspiré l'élaboration d'un nouvel indice spatio-temporel pour la détection robuste de changements, présenté ci-dessous.

5.2. Un nouveau descripteur spatio-temporel

La séparation en deux classes *changement/non changement* des nombreuses classes de changements produites par le classifieur multispectral *mean shift* est effectuée grâce à une nouvelle caractéristique spatio-temporelle : le taux de fragmentation. En effet, la complexité d'un paysage s'accroît avec le temps. La tendance à la diversification et à la fragmentation du paysage qui s'en suivent se traduit dans l'image par des régions plus hétérogènes. La présence d'hétérogénéité (à un degré plus ou moins élevé) dans une zone initialement homogène serait donc synonyme de changement. Dans le contexte des effets de tempête en forêt, la notion de diversification et de fragmentation de paysage se traduit par la déstructuration d'un ensemble forestier, relativement homogène et structuré, par la chute d'arbres ou la rupture des houppiers (arbres décapités). Le taux de fragmentation est calculé à partir de la comparaison des segmentations avant et après changement, et caractérise le degré de fragmentation des régions avant changement.

Le taux de fragmentation (TF) d'une région avant changement R_t est défini comme suit :

$$TF(R_t) = 1 - \frac{\max_j [A(R_t) \cap A(R_{t+dt}^j)]}{A(R_t)} \text{ avec } R_t \cap R_{t+dt}^j \neq \emptyset \quad (2)$$

où A est l'aire d'une région, R_{t+dt}^j la région après la date de changement ($t+dt$), incluse entièrement ou partiellement dans la région avant changement. Ce critère représente, du moins partiellement (cas d'une région), le dual du critère PS (cf équation 1) introduit précédemment pour évaluer la qualité de la segmentation. Le taux de fragmentation est ensuite moyenné par classe de changement. Le taux de fragmentation des classes de changement est défini de la manière suivante :

$$TF_{CC} = \frac{1}{N} \sum_{p \in CC} [TF(R_t(p))] \quad (3)$$

où CC est la classe de changement, N le nombre de pixels p correspondants.

Ces zones sont alors regroupées en deux classes : *changement/non changement*, en fonction de leur taux de fragmentation, par la technique de seuillage non supervisée de Otsu (1979). Cette méthode applique un seuillage qui minimise la variance intra-classes, l'hypothèse sous-jacente étant une séparation entre deux classes gaussiennes.

6. Complexité

Soient N et n ($n \ll N$) respectivement le nombre de pixels des images multispectrales et des mires correspondantes. Soit k le nombre de jeux d'attributs considérés dans la sélection d'attributs et p le nombre de jeux de paramètres utilisés dans le paramétrage automatique de l'algorithme du *mean shift*. La complexité globale de la méthodologie utilisée est en $O(N^2)$ si on considère que $k \ll N$ et $p \ll N$. L'approche consiste essentiellement en trois étapes dont la complexité est :

- en $O(kpn^2)$ pour la sélection d'attributs via les mires basée sur l'algorithme du *mean shift* dont la complexité est en $O(n^2)$,
- en $O(N^2)$ pour la segmentation de la paire d'images multispectrales,
- en $O(N^2)$ pour la classification binaire de l'image bi-temporelle,

les deux dernières étapes étant basées sur l'algorithme du *mean shift* dont la complexité est en $O(N^2)$.

Par exemple, si on ne prend pas en compte l'information de texture qui engendre des coûts de calculs prohibitifs, voici les temps de calcul obtenus sur un PC standard (fréquence : 3 Ghz, RAM : 4 Go) :

- En utilisant une recherche exhaustive de toutes les combinaisons possibles d'attributs, le temps de calcul de la sélection d'attributs est de 1 mn 34 s pour la segmentation de l'image avant tempête (juste les bandes spectrales), 39 mn 53 s

pour la segmentation de l'image après tempête (bandes spectrales + ratios), et 3 mn 45 s pour la classification binaire (juste les attributs temporels).

– La segmentation prend 1 mn sur l'échantillon d'image avant tempête, et 1 mn 30 s sur l'échantillon d'image après tempête (figure 1).

– La classification binaire de l'image bi-temporelle (détection de changements) prend 4 mn 49 s.

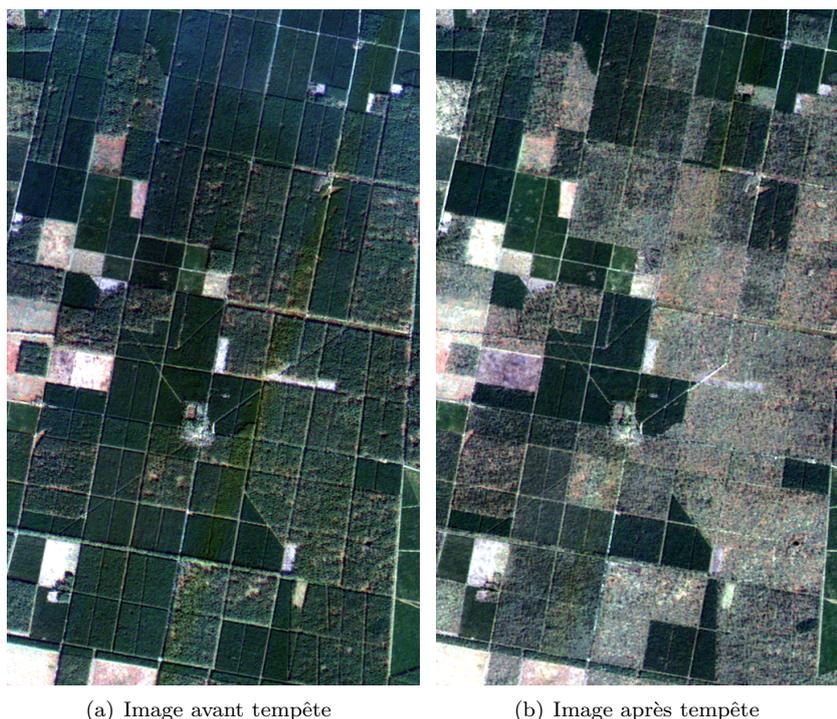


Figure 1. Couple d'images multispectrales Formosat-2 (échantillons de taille 845×511 pixels) avant et après la tempête Klaus

7. Résultats expérimentaux

Notre méthode de détection de changements a été évaluée sur un couple d'images satellite multispectrales Formosat-2 de la forêt de Nezer acquises avant (22/12/2008) et après (4/02/2009) la tempête Klaus (voir figure 1) qui a lourdement affecté cette forêt de pin maritime. Elles ont été analysées à l'aide de la librairie *open source* OTB (www.orfeo-toolbox.org) développée par le CNES¹.

1. Centre National d'Etudes Spatiales.

La détection de dégâts de tempête consiste à rechercher des groupes d'arbres de même structure avant et après la tempête. Les structures avant tempête sont caractérisées principalement par la densité des arbres, leur distribution spatiale, la hauteur des arbres et le diamètre des couronnes. Les structures après tempête sont caractérisées par ces variables et également par le type de dommage subi à l'échelle de l'arbre (arbre penché, couché, déraciné, cassé), et la distribution spatiale des dégâts et leur intensité.

Les régions avant tempête correspondent à des zones structurellement homogènes car appartenant à un même peuplement ou un groupe de peuplements d'âge voisin. Les régions après tempête représentent des zones structurellement et temporellement cohérentes. Elles exhibent des changements de réflectance dus aux dommages subis par les arbres qui peuvent être de différents types et d'intensité variable selon la structure initiale de la forêt.

7.1. Attributs et paramétrages utilisés

Un total de 84 attributs est utilisé et testé de façon automatique : 6 attributs spectraux, 10 texturaux et 3 bi-temporels, calculés sur les 4 bandes spectrales et les deux indices de végétation (voir tableau 1), soit 60 attributs texturaux et 18 attributs temporels toutes bandes confondues. Pour chaque attribut, des résolutions radiométriques h_r de 2 à 60 ont été expérimentées alors que la résolution spatiale h_s est fixée à priori à 3 pixels par des connaissances thématiques sur la forêt (Orny *et al.*, 2010). Ceci correspond à une fenêtre d'analyse suffisamment grande pour filtrer le fort contraste intra-parcellaire entre végétation éclairée et ombragée, et suffisamment petite pour détecter de petites zones de changement. Les paramètres de l'analyse de texture ont été fixés à 1 pixel aussi bien pour le rayon de la fenêtre d'analyse que pour l'amplitude du vecteur directionnel, la direction de celui-ci étant horizontale. La quantification des données initiales a été fixée à une valeur standard en télédétection (nbbins = 8).

Les trois différents types d'attributs (spectral, textural, temporel) sont utilisés pour caractériser les régions après tempête alors que seuls les attributs spectraux et texturaux sont considérés pour décrire les régions avant tempête. La séparation des zones de dégâts des zones intactes (classification binaire) n'exploite elle, que les attributs temporels.

7.2. Sélection automatique d'attributs

Les différentes caractéristiques sont segmentées et évaluées individuellement ou concaténées en une mire multi-attribut après normalisation. Pour éviter les effets de bord, le traitement des échantillons de la mire est effectué directement sur les images d'origine, de façon automatique.

Tableau 1. Attributs utilisés

Spectral	Textural	Temporel
Bleu	Moyenne	Différence Ratio Corrélation
Vert	Variance	
Rouge	8 attributs d'Haralick :	
PIR	moyenne, inertie (contraste), entropie,	
NDVI	énergie (second moment angulaire),	
SAVI	homogénéité (moment de la différence inverse), moyenne des sommes, variance des sommes, entropie des sommes.	

7.2.1. Attributs optimaux pour la segmentation

La figure 2 présente un exemple de mire à 4 échantillons. La mire segmentée exhibe principalement deux erreurs de segmentation dues à des confusions entre deux régions de même catégorie (dégât) et d'âges proches (29 et 38 ans), et donc de caractéristiques spectrales, texturales et temporelles proches.

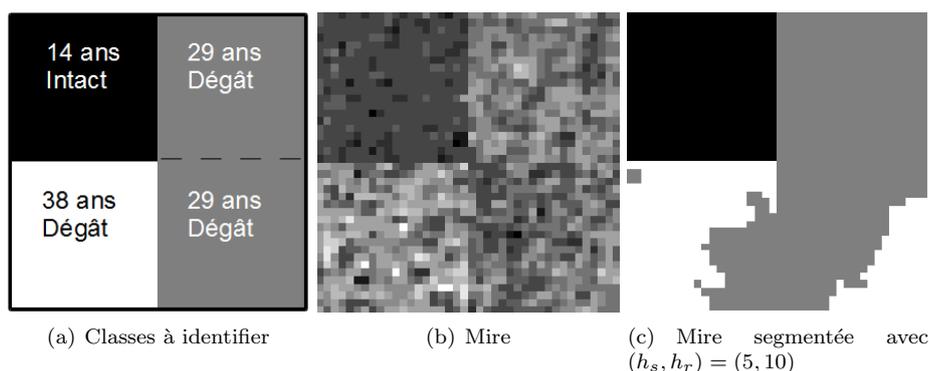


Figure 2. Segmentation d'une mire à 4 échantillons de taille 20×20 pixels.
La performance de segmentation est de 86 %

Les résultats de performance et de paramétrage obtenus pour la segmentation avec des mires mono ou multi-attributs, contenant 4 échantillons, sont présentés sur le tableau 2. Les meilleurs attributs pour les deux types de segmentation sont ceux utilisant la bande rouge. Notons que la 2^e meilleure performance de segmentation pour l'image avant tempête est le NDVI (qui combine des bandes Rouge et PIR).

On peut relever que les meilleures performances sont obtenues pour des mono-attributs, la segmentation multi-attribut s'avérant moins efficace ici. Néanmoins, celle-ci n'a pas été évaluée dans les meilleures conditions, puisque l'implémentation du *mean shift* utilisée n'autorise qu'une seule résolution spectrale h_r pour toute l'image multi-bande, d'autant plus que les images de télédé-

Tableau 2. Attributs et résolutions radiométriques h_r optimaux pour la segmentation après tempête et avant tempête d'une mire construite avec 4 échantillons. PS est la performance de segmentation (cf Eq. 1)

Segmentation après tempête			Segmentation avant tempête		
Attribut	h_r	PS (%)	Attribut	h_r	PS (%)
Ratio Rouge	17	87,2	Rouge	2	80,7
Rouge	3	78,1	NDVI	3	77,3
Ratio Vert	16	75,5	Vert	5	68,7

tection ont des distributions radiométriques différentes sur chaque bande. En effet, l'algorithme du *mean shift* a été initialement proposé pour la segmentation d'images couleur et de niveaux de gris (Comaniciu, Meer, 2002). L'intégration d'un h_r adapté à chaque bande constitue une des perspectives majeures de ce travail. Un effort méthodologique de normalisation spécifique à chaque bande est aussi une piste envisageable pour effectuer la segmentation multi-attribut dans des conditions plus optimales. Ce résultat pourrait aussi provenir du fait que les couverts forestiers sont complexes et texturés, et que leur variabilité dépend de nombreuses caractéristiques (dimensions des arbres, densité, régularité de la distribution spatiale des arbres, etc.) pas toutes indicatives du niveau de dégât.

Le fait que les attributs texturaux ne comptent pas parmi les caractéristiques optimales à l'issue du processus de sélection d'attributs est probablement dû à la résolution spatiale utilisée (8 m) qui serait insuffisante pour capturer l'information texturale, particulièrement pertinente dans le contexte de la forêt. De plus, les paramètres d'Haralick n'ont pas été optimisés.

7.2.2. Attributs optimaux pour la classification binaire

Les résultats de performance et de paramétrage obtenus pour la classification binaire des régions en classes endommagées et intactes avec des mires mono ou multi-attributs contenant 2 échantillons sont présentés sur le tableau 3. La différence bi-temporelle dans le vert donne le meilleur résultat. Comme dans le cas de la segmentation, les attributs texturaux et/ou multiples ne fournissent pas les meilleures performances.

Tableau 3. Attributs optimaux pour la classification binaire (dégât/non dégât) d'une mire construite avec 2 échantillons (avec $h_r = 2$)

Attribut bi-temporel	PS (%)
Différence Vert	92,6
Différence PIR	70,5
Différence Rouge	64,5

7.2.3. Analyse thématique

Le fait que les attributs les plus pertinents pour segmenter les images avant et après tempête soient relatifs à la bande rouge est compatible avec les connaissances thématiques. En effet, le recouvrement du sol par les couronnes d'arbres, lié à la densité des arbres et à la taille de leurs couronnes, explique en grande partie la variabilité de la réflectance rouge, alors que la réflectance PIR dépend plus de la biomasse verte des arbres et de la végétation de sous-bois (Guyon *et al.*, 2001). Ces propriétés de la bande rouge sont importantes pour décrire la structure de la forêt avant tempête, autrement dit, la fraction de couvert d'arbres sur pied, et pour détecter leur changements après tempête, dus principalement aux arbres couchés ou déracinés, réduisant la fraction de couvert de couronnes sans influence immédiate sur la biomasse verte, et augmentant par conséquent la contribution du sol. Le ratio rouge (rapport des bandes rouges entre les deux dates) est plus performant que la bande rouge pour l'image après-tempête car l'image de ratio permet de prendre en compte la modification de structure, due à la tempête, qui dépend de la structure initiale du couvert forestier.

L'interprétation thématique des attributs sélectionnés en 3^e position pour la segmentation des images avant et après-tempête (bande verte et ratio vert) devient plus difficile. En effet, on ne connaît pas bien les variations spatiales de la réflectance du sous-bois dans le rouge et dans le vert, même si on peut supposer qu'elle est faible (sous-bois pratiquement sec en hiver).

La différence des bandes vertes est la plus performante pour la classification binaire. C'est peut-être un effet de l'augmentation de la contribution du sous-bois avec les dégâts de tempête qui se traduirait par une augmentation plus sensible de la réflectance verte que de la réflectance rouge.

On peut noter aussi que, comme évoqué précédemment (voir section 5), la bande bleue ne compte pas parmi les bandes les plus discriminantes ni les plus représentatives de la structure avant ou après tempête. En effet, aucun attribut issu de cette bande n'est représenté parmi les 3 meilleurs attributs pour la classification (voir tableau 3) ni pour la segmentation (voir tableau 2).

7.3. Détection de changements

Le classifieur multispectral *mean shift* reçoit en entrée les régions issues de la segmentation *mean shift* des images avant et après tempête. La résolution radiométrique h_r du *mean shift* est fixée à une valeur faible (2) pour permettre la détection des changements les plus légers.

Une analyse comparative est effectuée par rapport à une approche pixel de détection de changements multi-temporelle non supervisée, basée sur un algorithme de partitionnement (*clustering*) bien connu : *K-means* (Duda *et al.*, 2001), et utilisant l'ensemble des 4 bandes disponibles de la paire d'images

multi-temporelles, autrement dit, sans sélection d'attributs. L'attribut temporel utilisé est la différence d'images. En effet, les résultats obtenus précédemment (tableau 3) ont montré que la différence était la plus performante, parmi les 3 types d'attributs temporels classiques évalués (corrélation, ratio et différence), pour la classification binaire.

7.3.1. Taux de fragmentation

La figure 3 illustre le calcul du taux de fragmentation sur des échantillons de forêt avant et après tempête et montre l'intérêt de ce nouveau descripteur spatio-temporel pour la détection de changements binaire (qui intègre aussi les résultats du classifieur multispectral *mean shift*).

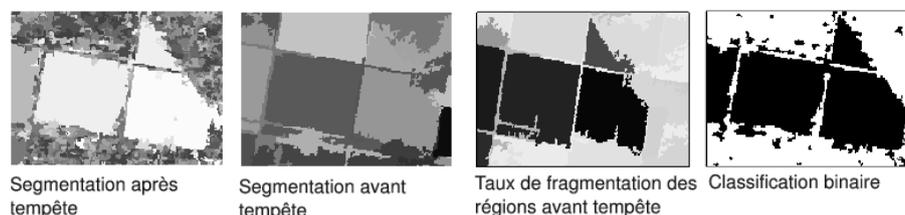


Figure 3. Segmentation et taux de fragmentation. Les parcelles sombres dans la 3^e image à droite sont moins fragmentées

La figure 4 montre le taux de fragmentation des régions avant tempête (après l'évènement) en niveaux de gris. Les zones de dégât sont identifiables sur l'image satellite après tempête (voir figure 1) et se superposent bien aux régions les plus claires de l'image du taux de fragmentation qui correspondent aux régions les plus fragmentées.

7.3.2. Classification binaire

Le tableau 4 montre les matrices de confusion globales obtenues pour les deux approches de détection de changement (notre approche *versus* approche pixel sans sélection d'attributs) en comparant pixel à pixel le résultat de classification binaire avec les données de référence. Celles-ci ont été extraites d'orthophotos de 15 cm de résolution, acquises par avion un mois après la tempête. Une centaine de zones de référence (100 % intactes ou 100 % touchées) y ont été délimitées. Leur surface moyenne est de $4\,806\text{ m}^2$ (~ 75 pixels), elle varie entre 198 m^2 (~ 3 pixels) et $23\,128\text{ m}^2$ (~ 260 pixels). La précision globale de classification est de 87,8 % pour notre méthode, et de 78,7 % pour l'approche pixel, soit une différence de performance de **9,1 %** qui met en évidence l'intérêt d'une approche région par rapport à une approche pixel pour la détection de changements. Elle souligne également l'apport de notre méthode de sélection automatique d'attributs et de notre descripteur spatio-temporel dans la chaîne de détection de changements. Le tableau 4 montre aussi que les erreurs d'omission et de commission sont pratiquement deux fois moins importantes pour



Figure 4. Taux de fragmentation des régions avant tempête

notre méthode, avec peu d'erreurs d'omission sur les zones intactes (5,3 %) et peu d'erreurs de commission sur les zones endommagées (3,2 %).

La confusion se produit entre les zones de dégâts forestiers et les vieux peuplements intacts hétérogènes et peu denses. Ces deux types de couverts ont effectivement des propriétés spectrales et texturales similaires, notamment une texture granuleuse irrégulière. D'autre part, il paraît difficile de détecter des zones de dégâts peu marqués (arbres penchés) dans les jeunes peuplements denses. De même, les très petites zones intactes ou endommagées ne sont pas détectées. Enfin, les effets d'ombrage ne sont pas explicitement pris en compte dans les processus de segmentation et de classification. Seul un jeu de données étant à notre disposition, il n'a pas été possible d'analyser l'influence de la longueur des ombres et de l'angle de vue sur la précision de classification. Ces sources potentielles d'erreurs d'étiquetage devraient être étudiées ultérieurement.

La cartographie finale de changements binaire *dégât/non dégât*, pour les deux méthodes concurrentes, est présentée sur la figure 5. On peut noter que notre méthode (figure 5a) exhibe des résultats plus lisses, et *a priori* de meilleure qualité visuelle, que ceux de l'approche pixel (figure 5b) du fait de la phase préliminaire de segmentation.

Tableau 4. Matrices de confusion de la classification binaire (dégât/non dégat) avec l'approche région basée sur le mean shift avec sélection d'attributs et l'approche pixel basée sur les K-means sans sélection d'attributs

Approche région				
	Vérité terrain		Total	Erreur de commission
	Intact	Dégât		
Intact	1 436	459	1 895	24,22
Dégât	81	2 452	2 533	3,2
Total	1 517	2 911	4 428	
Erreur d'omission	5,34	15,77		
Précision globale	87,80			

Approche pixel				
	Vérité terrain		Total	Erreur de commission
	Intact	Dégât		
Intact	1 361	788	2 149	36,67
Dégât	156	2 123	2 279	6,85
Total	1 517	2 911	4 428	
Erreur d'omission	10,28	27,07		
Précision globale	78,68			

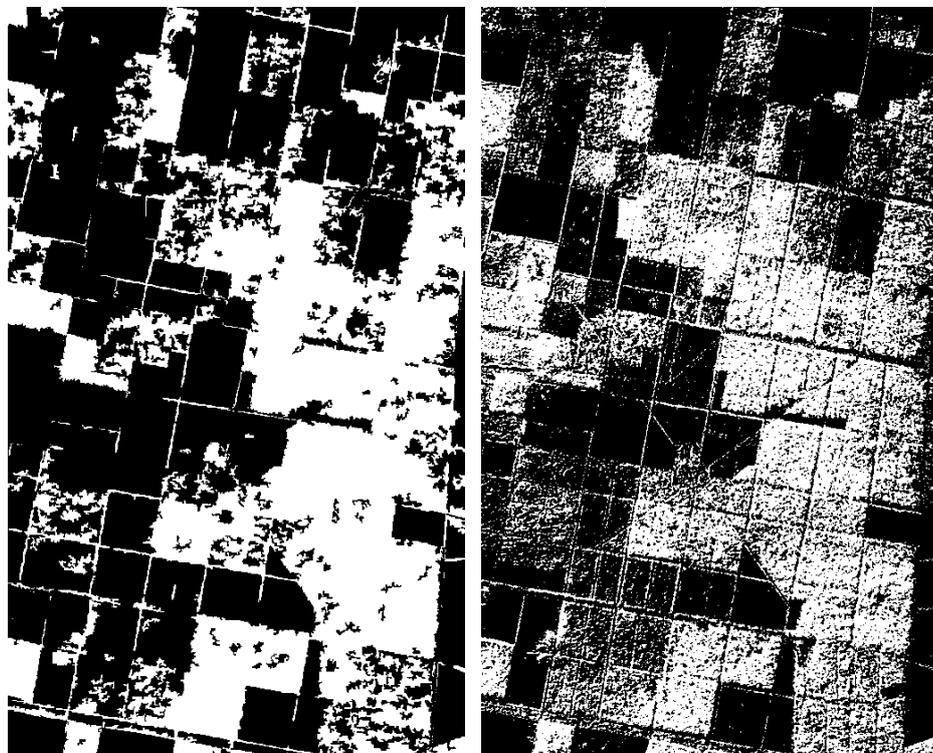
7.3.3. Analyse thématique

La précision de classification augmente significativement avec l'âge (figure 6). La précision des parcelles âgées de 14 à 39 ans (4 classes intermédiaires) est élevée alors que les deux classes d'âge les plus jeunes et la plus vieille ont un taux de détection plus faible.

Le taux de dégat, estimé sur tous les peuplements comme le rapport entre surface détectée endommagée et surface totale, augmente avec l'âge pour les couverts âgés de 10 à 30 ans, comme le montre la figure 6. L'augmentation du taux de dégat estimé avec l'âge n'est pas inattendue puisque la hauteur des arbres, qui augmente avec l'âge, est un des principaux facteurs qui interviennent dans la vulnérabilité des arbres face au vent. Les taux de dommage estimés sont élevés et affectent environ 70 % des peuplements dépassant 25 ans d'âge. Cette étroite relation entre âge et taux de dégat estimé est un bon indicateur de la qualité des résultats obtenus, d'autant plus que l'incertitude la plus élevée est observée pour les parcelles les plus jeunes où le taux de dégat estimé élevé est peu probable.

7.4. Influence de la sélection d'attributs sur la précision finale de cartographie

Pour vérifier la pertinence de la sélection d'attributs, la segmentation de la scène a été réalisée sur l'ensemble des bandes disponibles aux 2 dates (8



(a) Approche région basée sur l'algorithme du *mean shift* avec sélection d'attributs (b) Approche pixel basée sur l'algorithme des *K-means* sans sélection d'attributs

Figure 5. Détection de changements non supervisée (zones de dégâts en blanc et zones intactes en noir)

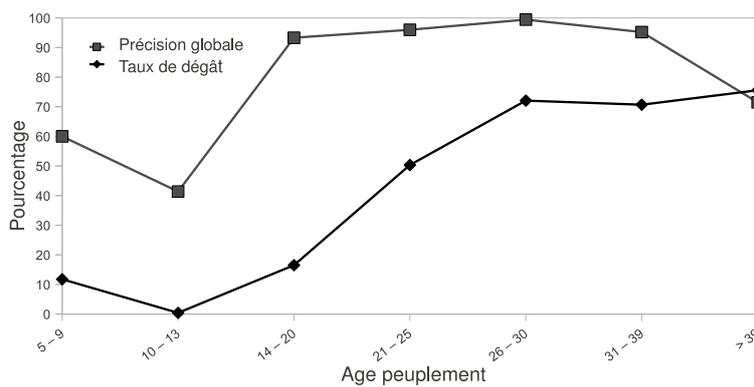


Figure 6. Précision de classification en fonction des classes d'âge

bandes). La précision finale de cartographie obtenue est alors de 83,8 % contre 87,8 % avec sélection automatique d'attributs, soit une différence de performance de 4 %. Il est intéressant de noter que la performance maximale atteinte par bande pour l'approche pixel basée sur l'algorithme des *K-means* est de 83,2 %, soit un gain de performance de l'ordre de 4,5 % par rapport à la précision atteinte en utilisant l'ensemble des bandes disponibles (78,7 %). Ceci confirme, comme mentionné précédemment, que l'utilisation systématique de toutes les bandes disponibles n'est pas forcément la stratégie la plus appropriée pour la segmentation et la classification multispectrale multi-temporelle. Ce résultat est cohérent avec les résultats obtenus en section 7.2 montrant que les mono-attributs offraient de meilleures performances que les attributs multiples pour la classification multi-temporelle binaire, du moins en milieu forestier.

7.5. Bilan sur l'aspect supervisé de l'approche

Notre méthode de détection de changement est quasi non supervisée. Elle permet d'élaborer une cartographie de changements à partir d'un minimum de données d'apprentissage qui consistent en :

1. Deux mires multispectrales de 40×40 pixels à 4 échantillons de taille 20×20 pixels avec classes d'âge et états de changement (dégât/non dégat) associés. Ces mires sont utilisées dans la sélection d'attributs pour la segmentation des images avant et après-tempête.
2. Une mire bi-temporelle de 40×40 pixels, combinant deux mires multispectrales extraites des images avant et après-tempête, à 2 échantillons de taille 40×20 pixels avec états de changement associés. Cette mire est utilisée dans la sélection d'attributs pour la classification binaire (dégât/non dégat).

Les données de référence (limitées aussi, voir section 7.3.2) utilisées pour valider l'approche proposée ne sont pas comptabilisées, d'autant plus que d'autres moyens que la matrice de confusion sont utilisés pour évaluer les approches non supervisées (Boukir *et al.*, 2012).

Le paramétrage de notre approche est partiellement automatique grâce à l'utilisation de mires. Les paramètres fixés encore manuellement sont :

- la résolution spatiale h_s du *mean shift*, fixée par des connaissances thématiques, et
- les paramètres de texture d'Haralick (taille de la fenêtre, amplitude et orientation du vecteur directionnel, quantification), fixés à des valeurs standards en télédétection.

Ces deux types de paramètres sont automatisables via les mires mais avec un coût de calcul supplémentaire important notamment pour optimiser le paramétrage de l'analyse de texture. Enfin, la taille de la mire a certainement un

impact sur la qualité de la segmentation et de la classification mais nous avons opté pour une supervision minimale et un compromis qualité/complexité.

8. Conclusion

La méthode de détection de changements environnementaux proposée est utile pour la cartographie d'urgence en cas de désastre car elle est quasi non supervisée. En effet, elle requiert pour sa mise en œuvre juste quelques petits échantillons pour la construction des mires, une supervision négligeable par rapport aux méthodes supervisées très contraignantes vis-à-vis de la collecte et de l'étiquetage des données de terrain.

Notre méthode de sélection automatique d'attributs permet l'évaluation d'un grand nombre d'attributs et de leurs combinaisons pour optimiser les phases de segmentation et de classification de la détection de changements. L'une des perspectives de ce travail consisterait à adapter la résolution radiométrique, le paramètre prépondérant dans l'algorithme du *mean shift*, à chaque attribut pour prendre en compte la variabilité de la distribution radiométrique entre bandes et ainsi mieux exploiter la combinaison d'attributs multiples. Le taux de fragmentation, un nouvel indice spatio-temporel, s'est avéré un moyen simple et efficace pour établir de façon automatique une carte binaire de changements à partir des différentes classes de changement fournies par le classifieur multispectral *mean shift*.

Notre schéma de détection de changements abrupts a été validé en milieu forestier. Il a permis la localisation précise des dégâts de tempête les plus sévères, à haute résolution. La précision globale de classification est de 87,8 % alors qu'elle n'est que de 78,7 % pour une approche pixel traditionnelle sans sélection d'attributs, soit une différence de performance de presque 10 %.

Notre approche sera évaluée sur les prochaines données Sentinel-2 (10 m de résolution sur les bandes spectrales (R, G, B, PIR) et pas de bande panchromatique), les données multispectrales Formosat-2 ayant servi à la simulation (voir par exemple (Hagolle *et al.*, 2010)) de ces données que leur résolution temporelle (moins de 5 jours avec les deux satellites Sentinel-2, lancement prévu en 2014 et 2015) rendra particulièrement propices à l'analyse des changements environnementaux. Elle pourra également être testée sur des images de très haute résolution spatiale, comme celles fournies par les satellites Pléiades lancés en 2011 et 2012 (70 cm en panchromatique et 2,4 m en multispectral), afin d'évaluer leurs performances pour la détection de changements forestiers abrupts comme ici ou plus subtils, qu'ils soient liés à une tempête (majeure, comme Klaus, ou non) ou à d'autres phénomènes. D'une résolution spatiale plus haute est attendue une plus riche information de texture des images de forêt et ainsi une amélioration de la performance de la détection de changements. Dans la même optique, les données de Formosat-2 en panchromatique, qui sont à 2 m de résolution, seront exploitées dans des travaux futurs afin d'évaluer l'impact

de la résolution spatiale sur la qualité de la détection des dégâts de tempête. Enfin, notre approche, qui se veut générique et non contrainte du point de vue applicatif, sera aussi évaluée sur d'autres écosystèmes, notamment en milieu littoral.

Remerciements

Cette étude a été financée par le CNES dans le cadre du programme Kalidéos Littoral et du programme Orféo. Ce dernier prépare l'utilisation future des images Pléiades. Les auteurs remercient l'INRA pour le financement des orthophotos avec le crédit tempête 2009. Ils remercient également Olivier Hagolle (CNES/Cesbio, Toulouse) et Christophe Moisy (INRA, EPHYSE, Bordeaux) pour le pré-traitement des images.

Bibliographie

- Blaschke T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 65, n° 1, p. 2 - 16.
- Bo S., Ding L., Li H., Di F., Zhu C. (2009). Mean shift-based clustering analysis of multispectral remote sensing imagery. *International Journal of Remote Sensing*, vol. 30, n° 4, p. 817–827.
- Boukir S., Jones S., Reinke K. (2012). Fast mean-shift based classification of very high resolution images. application to forest cover mapping. In *Isprs'2012, xxii international society for photogrammetry & remote sensing congress, isprs annals of photogrammetry, remote sensing and the spatial information sciences, melbourne, australia*, vol. I-7, p. 111-116.
- Boukir S., Orny C., Chehata N., Guyon D. (2011). Classification multitemporelle des dégâts de tempête en forêt sur des images satellite haute résolution. In *23ème colloque gretsi - traitement du signal et des images, bordeaux*.
- Bruzzone L., Prieto D. (2000). Automatic analysis of the difference image for unsupervised change detection. *IEEE Trans. on Geoscience and Remote Sensing*, vol. 38, n° 3, p. 1171-1182.
- Chehata N., Orny C., Boukir S., Guyon D. (2011). Object-based forest change detection using high resolution satellite images. In *Pia'2011, isprs photogrammetric image analysis conference, international archives of photogrammetry, remote sensing and spatial information sciences, munich, germany*, vol. 38, p. 49-54.
- Cheng H., Jiang X., Sun Y., Wang J. (2001). Color image segmentation : advances and prospects. *Pattern Recognition*, vol. 34, n° 12, p. 2259-2281.
- Clandillon S., Yesou H., Meyer C. (2003). Benefits of spot 5 hr and vhr data for forest management and windfall damage mapping. In *Ieee international geoscience and remote sensing symposium, igarss '03*, vol. 5, p. 3079 - 3081.
- Comaniciu D., Meer P. (2002). Mean shift : A robust approach toward feature space analysis. *IEEE Transactions on pattern analysis and machine intelligence*, vol. 24, n° 5, p. 603–619.

- Conchedda G., Durieux L., Mayaux P. (2008). An object-based method for mapping and change analysis in mangrove ecosystems. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 63, n° 5, p. 578–589. (Theme Issue: Remote Sensing of the Coastal Ecosystems)
- Coppin P., Jonckheere I., Nackaerts K., Muys B., Lambin E. (2004). Digital change detection methods in ecosystem monitoring : a review. *Int. Jour. of Remote Sensing*, vol. 25, n° 9, p. 1565-1596.
- Desclée B., Bogaert P., Defourny P. (2006). Forest change detection by statistical object-based method. *Remote Sensing of Environment*, vol. 102, n° 1-2, p. 1–11.
- Duda R., Hart P., Stork D. (2001). *Pattern classification* (2nd ed.). Wiley-Interscience.
- Franklin S., Waring R., McCreight R., Cohen W., Fiorella M. (1995). Aerial and satellite sensor detection and classification of western spruce budworm defoliation in a subalpine forest. *Canadian Journal of Remote Sensing*, vol. 21, p. 299 - 308.
- Fraser R., Abuelgasim A., Latifovic R. (2005). A method for detecting large-scale forest cover change using coarse spatial resolution imagery. *Remote Sensing of Environment*, vol. 95, n° 4, p. 414–427.
- Fukunaga K., Hostetler L. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Transactions on Information Theory*, vol. 1, p. 32-40.
- Fuller R., Smith G., Devereux B. (2003). The characterisation and measurement of land cover change through remote sensing : problems in operational applications. *Int. Jour. of Applied Earth Observation and Geoinformation*, vol. 4, p. 243-253.
- Gonzales R. C., Woods R. E. (2008). *Digital image processing* (P. I. Edition, Ed.). Pearson Education Inc.
- Guyon D., Courrier G., Berbigier P. (2001). Sensitivity analysis of coniferous forest reflectance with canopy structure and undergrowth characteristics from satellite data and modelling (case study: Landes maritime pine forest). In C. Ed (Ed.), *8th international symposium " physical measurements and signatures in remote sensing"*, p. 387-392. Aussois, France.
- Hagolle O., Huc M., Pascual D. V., Dedieu G. (2010). A multi-temporal method for cloud detection, applied to formosat-2, ven μ s, landsat and sentinel-2 images. *Remote Sensing of Environment*, vol. 114, p. 1747-1755.
- Haralick R., Shanmugan K., Dinstein I. (1973). Texture features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 3, p. 610 - 621.
- Huang C., Song K., Kim S., Townshend J., Davis P., Masek J. G. *et al.* (2008). Use of a dark object concept and support vector machines to automate forest cover change analysis. *Remote Sensing of Environment*, vol. 112, n° 3, p. 970–985.
- Im J., Jensen J. (2005). A change detection model based on neighborhood correlation image analysis and decision tree classification. *Remote Sensing of Environment*, vol. 99, n° 3, p. 326–340.

- Johansen K., Arroyo L., Phinn S., Witte C., Kauth R., Thomas G. (2010). Comparison of geo-object based and pixel-based change detection of riparian environments using high spatial resolution multi-spectral imagery. *Photogrammetric Engineering and Remote Sensing*, vol. 76, n° 2, p. 123–136.
- Johansen K., Coops N., Gergel S., Stange Y. (2007). Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification. *Remote Sensing of Environment*, vol. 110, n° 1, p. 29–44.
- Kennedy R., Townsend P., Gross J. E., Cohen W., Bolstad P., Wang Y. *et al.* (2009). Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects. *Remote Sensing of Environment*, vol. 113, n° 7, p. 1382-1396.
- King D. J., Olthof I., Pellikka P. K. E., Seed E. D., Butson C. (2005). Modelling and mapping damage to forests from an ice storm using remote sensing and environmental data. *Natural Hazards*, vol. 35, p. 321 - 342.
- Liu D., Song K., Townshend J., Gong P. (2008). Using local transition probability models in markov random fields for forest change detection. *Remote Sensing of Environment*, vol. 112, n° 5, p. 2222–2231. (Earth Observations for Terrestrial Biodiversity and Ecosystems Special Issue)
- Lunetta R., Johnson D., Lyon J., Croswell J. (2004). Impacts of imagery temporal frequency on land cover change detection monitoring. *Remote Sensing of Environment*, vol. 89, p. 444-454.
- Makela H., Pekkarinen A. (2001). Estimation of timber volume at the sample plot level by means of image segmentation and lansat tm imagery. *Remote Sensing of Environment*, vol. 77, p. 66-75.
- 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*, vol. 63, n° 2, p. 237–250.
- Melgani F., Bruzzone L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Trans. on Geosciences and Remote Sensing*, vol. 42, n° 8, p. 1178-1790.
- Meyer C., Geldreich P., Yesou H. (2001). Apports des données simulées spot5 pour l'évaluation des dégâts de tempête dans la forêt. cas de la forêt de haguenau (alsace, france). In *Bulletin de la société française de photogrammétrie et de télé-détection*, vol. 164-165, p. 162-173.
- Nielsen A., Conradsen K., Simpson J. (1998). Multivariate alteration detection (mad) and maf postprocessing in multispectral, bitemporal image data: New approaches to change detection studies. *Remote Sensing of Environment*, vol. 64, n° 1, p. 1-19.
- Olthof I., King D. J., Lautenschlager R. (2004). Mapping deciduous forest ice storm damage using landsat and environmental data. *Remote Sensing of Environment*, vol. 89, p. 484-496.

- Orny C., Chehata N., Boukir S., Guyon D. (2010). *Characterization of maritime pine forest structure changes with vhr satellite imagery : application to the 24th january 2009 windfall damages cartography*. Tech. Rep.. CNES.
- Pacifici F., Frate F. D., Solimini C., Emery W. (2007). An innovative neural-net method to detect temporal changes in high-resolution optical satellite imagery. *IEEE Trans. on Geosciences and Remote Sensing*, vol. 45, n° 1, p. 217-222.
- Richards J. A., Jia X. (1999). *Remote sensing digital image analysis: An introduction*. Springer.
- Ruiz L. A., Fdez-sarría A., Recio J. A. (2004). Texture feature extraction for classification of remote sensing data using wavelet decomposition: a comparative study. In *International archives of photogrammetry and remote sensing. vol.xxxv*, p. 1682–1750.
- Schwarz M., Steinmeier C., Waser L. (2001). Detection of storm losses in alpine forest areas by different methodic approaches using high resolution satellite data. In *Proceedings of the 21st earsel symposium: Observing our environment from space: New solutions for a new millenium*, p. 251–257.
- St-Louis V., Pidgeon A., Radeloff V., T.J.Hawbaker, Clayton M. (2006). High-resolution image texture as a predictor of bird species richness. *Remote Sensing of Environment*, vol. 105, p. 299-312.
- Taud H., Couturier S., Carrillo-Rivera J. (2012). Remote sensing image classification by mean shift and colour quantization. In *Image and signal processing for remote sensing xviii. proceedings of the spie*, vol. 8537.
- 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*, vol. 63, p. 156-168.
- Tuominen S., Pekkarinen A. (2005). Performance of different spectral and textural aerial photograph features in multi-source forest inventory. *Remote Sensing of Environment*, vol. 94, p. 256-268.
- Wang Y., Soh Y., Shultz H. (2006). Individual tree crown segmentation in aerial forestry images by mean shift clustering and graph-based cluster merging. *Computer Science and Network Security*, vol. 6, n° 11, p. 40 - 45.

Samia Boukir. *Professeur en informatique à l'ENSEGID/IPB de Bordeaux. Elle est membre du laboratoire G&E (Géoressources et Environnement). Ses activités de recherche concernent principalement la classification et l'apprentissage automatique avec des applications en télédétection, notamment la cartographie de l'occupation du sol et la détection de changements environnementaux.*

Camille Orny. *Ingénieur agronome spécialisé en télédétection. Elle a travaillé dans le cadre du programme ORFEO du CNES aux laboratoires G&E (Géoressources et Environnement) de l'Université de Bordeaux 3 et EPHYSE de l'INRA de Bordeaux. Ses activités de recherche concernent principalement le traitement d'images de télédétection avec des applications en milieu forestier.*

Nesrine Chehata. *Maître de conférences en informatique à l'ENSEGID-IPB, actuellement en délégation à l'IRD - UMR LISAH. Elle s'intéresse au traitement d'images pour la télédétection. Ses travaux portent sur les classifieurs d'ensemble et la sélection d'attributs. Elle s'intéresse tout particulièrement au lidar aéroporté et à la télédétection optique à très haute résolution spatiale ou spectrale, pour diverses applications environnementales.*

Dominique Guyon. *Ingénieur de recherche à l'INRA. Elle fait partie de l'équipe Télédétection et Spatialisation de l'UMR ISPA du centre INRA de Bordeaux-Aquitaine. Ses travaux portent sur les applications forestières de la télédétection optique, et plus particulièrement sur le suivi de la dynamique spatio-temporelle de la ressource forestière sous l'effet de la gestion forestière, des accidents climatiques et du changement global.*

Jean-Pierre Wigneron. *Directeur de recherches à l'INRA. Il anime l'équipe Télédétection et Spatialisation de l'UMR ISPA sur le centre INRA de Bordeaux-Aquitaine. Il est membre du bureau éditorial de Remote Sensing of Environment depuis 2005. Il s'intéresse plus particulièrement aux applications de la télédétection dans le suivi du cycle de l'eau (projets SMOS et SMAP) et des forêts.*

