*Télédétection*, 2004, vol. 4, n°3, p. 289-301
Droit de photocopie soumis à l'autorisation

© 2004 CONTEMPORARY PUBLISHING INTERNATIONAL
Publié sous l'enseigne *Éditions scientifiques GB*

# COMBINAISON DE CLASSIFIEURS : UNE APPROCHE POUR L'AMÉLIORATION DE LA CLASSIFICATION D'IMAGES MULTISOURCES/MULTIDATES DE TÉLÉDÉTECTION

SALIM CHITROUB

*Laboratoire de traitement du signal et d'image, Faculté d'électronique et d'informatique,*
*Université des Sciences et Technologie Houari Boumediene,*
*B.P. 32, El-Alia, Bab-Ezzouar, 16111, Alger, Algérie*
*Télécopieur : (213) (21) 24-76-07 et (213) (21) 24-71-87*
*Courriel : s_chitroub@hotmail.com ; schitroub@usthb.dz*

*(soumis : 9 mars 2004 ; révisé : 5 juillet 2004 ; accepté 8 septembre 2004)*

Dans cet article, nous proposons une méthode de combinaison de classifieurs pour l'amélioration de la classification des images multisources/multidates de télédétection. La méthode est basée sur le principe de la combinaison parallèle des systèmes répartis (classifieurs) en utilisant la théorie de l'évidence. Les entrées des classifieurs peuvent être des images de même type (optique ou radar), des images multisources/multicapteurs optiques et radar ou des images multidates. De ce fait, l'utilisation conjointe des images satellitaires multisources optiques et radar ainsi qu'une étude diachronique des territoires observés par les capteurs de télédétection sont possibles. En effet, la méthode permet de détecter les changements naturels subis par le territoire observé. Elle permet aussi de mieux appréhender l'évolution de l'état de surface et, par conséquent, de mieux interpréter les phénomènes liés à la modification de l'environnement. L'objectif principal à atteindre est l'établissement de cartes thématiques précises pour la caractérisation de l'état de surface, la détection de changements et le suivi de l'environnement. Nous utilisons le taux de fiabilité de la classification comme critère d'évaluation. Les résultats obtenus sur des images simulées et des images réelles de télédétection (multisources et multidates) sont satisfaisants et prometteurs. Ils montrent que la méthode proposée donne de meilleurs résultats en comparaison avec celles des classifieurs considérés séparément.

*Mots-clefs : télédétection ; cartographie ; détection de changements ; classification multisource ; fusion d'images ; combinaison de classifieurs ; théorie de l'évidence.*

# COMBINATION OF CLASSIFIERS : AN APPROACH FOR MULTISOURCE/MULTITEMPORAL REMOTE SENSING IMAGE CLASSIFICATION ENHANCEMENT

In this article, we propose a new method of combination of classifiers for multisource/ multitemporal remote sensing images classification enhancement. The method is based on parallel combination of distributed systems using the theory of evidence. The entries of the classifiers can be the images of the same type (optical or radar), the multisource/ multisensor images (optical and radar) or the multitemporal images. Therefore, the joint use of the multisource satellite images as well as a diachronic study of the observed scenes is possible. In fact, the method makes it possible to detect the natural changes undergone by the observed scene. In addition, it makes it possible to better apprehend the evolution of the surface state and consequently to better interpret the phenomena related to the modification of the environment. The principal objective to reach is the establishment of the precise thematic maps for state surface characterization, change detection and the follow-up of the environment. We use the rate of reliability of classification like criterion of evaluation, and by using the simulated images and real remote sensing images (multisource and multitemporal); the obtained results are satisfactory and promising. They show that the suggested method gives better results in comparison with those given by the classifiers separately considered.

*Keywords : remote sensing ; cartography ; change detection ; multisource classification ; image fusion ; combination of classifiers ; theory of evidence.*

## 1. INTRODUCTION

Les problèmes de la classification des images multisources/multidates de télédétection spatiale sont en général complexes. Les images fournies par les capteurs de télédétection sont obtenues dans des conditions de prise de vue difficiles à contrôler. En effet, en traversant l'atmosphère, la réponse réfléchie par l'objet terrestre est modifiée par les constituants de cette atmosphère. Ceci se traduit par un bruit qui se rajoute au contenu du pixel. Les mouvements mécaniques du satellite provoquent des vibrations dans les composants électroniques, ce qui a pour effet de déformer le contenu réel du pixel. De plus, la non disponibilité d'informations *a priori*, déterministes et fiables, sur l'état et les conditions de fonctionnement du système d'acquisition ainsi que sur l'état de surface de l'image au moment de la prise de vue, rend la classification d'images de télédétection un problème mal posé (Tikhonov and Arsenin, 1977).

Plusieurs classifieurs peuvent donner des réponses différentes sur l'attribution d'un pixel de l'image à une classe donnée. Ceci est dû à la qualité du contenu du pixel et à l'incertitude spécifique au classifieur. Cette incertitude dépend du modèle de décision du classifieur et de la base de données utilisée pour son apprentissage. Aucune méthode de classification ne peut satisfaire entièrement les exigences d'une application envisagée. L'utilisation simultanée de plusieurs méthodes en même temps peut, éventuellement, permettre d'en cumuler les avantages sans en cumuler les inconvénients. En effet, l'exploitation des différentes informations, que les classifieurs fournissent en utilisant des techniques de combinaison de classifieurs, peut aboutir à une image classifiée plus précise. Même si le classifieur est moins performant, la connaissance de son comportement apporte une certaine information utilisable à propos de la vraie classe du pixel traité (Bonnin *et al.*, 1995 ; Rosenberger and Chehdi, 2000).

Dans le contexte des applications de télédétection, telles que la détection des changements et la cartographie, les entrées des classifieurs peuvent être des images multisources optiques et radar ou des images multidates. De ce fait, l'utilisation conjointe des images, satellitaires multisources, optiques et radar, ainsi qu'une étude diachronique des images acquises par les capteurs de télédétection sont possibles. Cependant, les résultats des classifieurs considérés séparément présentent des incertitudes de classification dues aux raisons citées ci-dessus. La combinaison de classifieurs permet de mieux détecter les changements naturels subis par le territoire observé. Elle permet aussi de mieux appréhender l'évolution de l'état de surface et, par conséquent, de mieux interpréter les phénomènes liés à la modification de l'environnement.

## 2. DONNÉES ET SITES D'ÉTUDE

Le premier jeu de données utilisé dans la première expérience est une image simulée (figure 1) de taille 251 pixels par 251 pixels. Elle est obtenue en bruitant l'image de réalité de terrain simulée (figure 1) par un bruit additif gaussien de variance 551.

La deuxième expérience a été effectuée sur une image multibande (XS1, XS2 et XS3) fournie par le capteur HRV du SPOT (image 50-282 du 23 février 1986). L'image représente une partie de la ville de Blida (situé sur la plaine fertile de la zone Mitidja, au nord d'Algérie, 140 pixels par 244 pixels). C'est une région agricole avec l'existence de quelques zones urbaines et de sol nu. Sept classes peuvent être distinguées, à savoir : zone urbaine moins dense, végétation naturelle moins dense, sol nu, champs non cultivés, zone urbaine dense, champs cultivés et végétation naturelle dense.

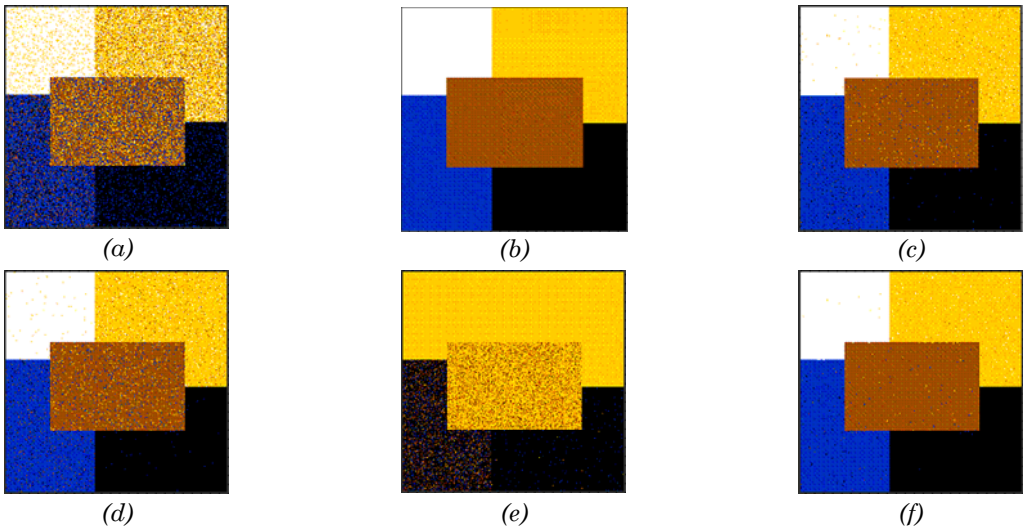



FIGURE 1 Résultats de la première expérience : (a) Image simulée bruitée, (b) Image de réalité de terrain simulée, (c) Résultat de la classification de minimum de distance euclidienne, (d) Résultat de la classification de minimum de distance de Mahalanobis, (e) Résultat de la classification de maximum de vraisemblance, (f) Résultat de la combinaison de trois classifieurs.*Results of the first experiment : (a) Noised simulated image, (b) Image of the ground truth, (c) Result of the minimum Euclidean distance classification, (d) Result of the minimum Mahalanobis distance classification, (e) Result of the maximum likelihood classification, (f) Result of the combination of the three classifiers.*

Le troisième jeu de données que nous avons utilisé est composé de deux ensembles d'images multibandes-multidates prises à deux années (images de 256 pixels par 256 pixels). Chaque ensemble est constitué des trois bandes spectrales XS du capteur HRV du SPOT. Les années de prise des deux images sont, respectivement, 1989 et 1991. La zone d'étude se trouve à l'est de la ville d'Alger. La correction géométrique entre les deux ensembles d'images a été faite en utilisant le logiciel ENVI (Chibani and Nemmour, 2003). Les thèmes présents dans la zone d'étude sont : la végétation, les zones agricoles, la mer, les zones urbaines, les constructions, le sol nu et les routes.

## 3. COMBINAISON DE CLASSIFIEURS ET THÉORIE DE L'ÉVIDENCE

Dans cette section, sont données les définitions exactes des termes fusion d'informations et combinaison d'informations. Ensuite, le sens de la combinaison de classifieurs, ainsi que les différents schémas de combinaison de classifieurs sont abordés, puis la théorie de l'évidence et son application en combinaison de classifieurs et en télédétection.

### *3.1. Fusion d'informations ou combinaison d'informations*

L'idée principale de la fusion de données est de combiner différentes informations relatives à un problème. Les informations fusionnées pouvant être de natures très variées. Elles peuvent être des données provenant de sources différentes ou bien présentant des caractéristiques différentes, extraites des mêmes données initiales. Pour cette raison, on trouve souvent dans la littérature le terme fusion d'informations au lieu de fusion de données. Dans un sens beaucoup plus large que la fusion d'informations, il a été suggéré d'utiliser le terme combinaison d'informations. Ces définitions sont dissociées intentionnellement et offrent différentes interprétations. La combinaison n'est pas définie comme un terme opposé à la fusion, mais elle est simplement plus générale. Une synthèse de l'ensemble des terminologies et des définitions de fusion (ou combinaison), ainsi que les techniques utilisées, sont données dans Benediktsson and Landgrebe (1999), Wald (1998), Kanal (1993) ainsi que Petrou et Stassopoulou (1999). Dans le présent article, il s'agit de combiner les réponses des classifieurs en proposant un schéma de combinaison parallèle des systèmes répartis, d'où le terme « combinaison de classifieurs » utilisé dans le reste de l'article.

### *3.2. Principes et schémas de combinaison de classifieurs*

L'idée principale derrière la combinaison de classifieurs est l'augmentation de la qualité des résultats. En effet, de plus en plus, les chercheurs se rendent compte qu'il n'existe aucune méthode de classification pouvant manifester une supériorité sur les autres méthodes dans tous les problèmes et toutes les situations (Kanal, 1993 ; Minsky, 1991 ; Chitroub *et al.*, 2000). Si aucune d'entre elles ne peut satisfaire entièrement les exigences d'une application envisagée, l'utilisation simultanée de plusieurs méthodes en même temps peut, éventuellement, permettre d'en cumuler les avantages sans en cumuler les inconvénients.

Différents schémas de combinaison de classifieurs ont été proposés dans la littérature selon les critères de combinaison (Kimura and Shridhar, 1991 ; Moobeb, 1996). Ainsi, on trouve le critère de l'ordre d'exécution des classifieurs où on observe trois types de combinaison : séquentielle, parallèle et série-parallèle. Un autre critère de combinaison est la combinaison avec bouclage où le résultat de combinaison peut à son tour être utilisé par les classifieurs et modifier ainsi leurs sorties. Il y a aussi le critère de combinaison avec interaction entre les classifieurs où les classifieurs interagissent entre eux et modifient leurs résultats avant que la combinaison ne soit réalisée. Enfin, le critère de combinaison utilise directement la forme $x$ d'entrée en même temps que les réponses des classifieurs.

### *3.3. Théorie de l'évidence*

La théorie de l'évidence permet de représenter à la fois l'imprécision et l'incertitude (Shafer, 1976 ; Appriou, 1991). L'utilisation de cette théorie est motivée par ses avantages dans les applications de télédétection (Srinivasan and Richards, 1990 ; Appriou, 1991 ; Cleynenbreugel *et al.*, 1991 ; Peddle and Franklin, 1992). Un premier avantage est sa capacité à modéliser l'ignorance et l'information manquante. En particulier, elle fournit des mesures explicites de l'imprécision et du conflit entre les informations provenant des différentes images. Deux informations sont conflictuelles si elles conduisent à des conclusions ou à des décisions contradictoires. Un autre avantage de la théorie de l'évidence est la possibilité de considérer non seulement des singletons, c'est-à-dire les classes individuelles, mais aussi des unions de classes (Le Hégarat-Mascle *et al.*, 1997 ; Chitroub *et al.*, 2001b, c, 2002), ce qui est particulièrement utile en présence de pixels mixtes et pixels des

régions ayant subi de faibles changements pour ce qui est des problèmes de classification.

En fait, dans le domaine de la classification d'images de télédétection, les notions d'imprécision et d'ambiguïté sont particulièrement liées à la présence de pixels bruités, de pixels mixtes et de pixels des régions ayant subi des changements. Dans le cas où certains pixels sont intermédiaires entre deux classes (comme ceux qu'on trouve aux limites de régions homogènes), ces pixels doivent être classés dans l'union des deux classes plutôt que dans une classe singleton. Ce cas peut être important lorsque la résolution spatiale du capteur est grande. Les pixels mixtes interviennent dans la modélisation d'une image monosource chaque fois que ladite source n'est pas capable de distinguer entre deux classes. Dans ce cas, seule l'information concernant l'union des classes est accessible. Dans les régions de faibles changements, les pixels sont difficiles à distinguer des pixels des régions stables et, par conséquent, il est nécessaire d'utiliser un outil mathématique qui permet de détecter les pixels de changement.

## 4. MÉTHODE DE COMBINAISON DE CLASSIFIEURS D'IMAGE DE TÉLÉDÉTECTION EN UTILISANT LA THÉORIE DE L'ÉVIDENCE

Le principe de la méthode proposée est de combiner les réponses des classifieurs sans tenir compte de leurs caractéristiques internes. De ce fait, la méthode se veut générale et applicable à tout type de classifieur. Le schéma de combinaison comporte plusieurs classifieurs en parallèle et un combineur (figure 2). Il n'y a pas d'interaction entre les classifieurs. Il n'y a pas de rebouclage du combineur vers les classifieurs. Les classifieurs sont fixes et ne changent pas. Le combineur n'a pas accès à l'entrée. Il traite les réponses des classifieurs et donne une réponse finale en utilisant la théorie de l'évidence.

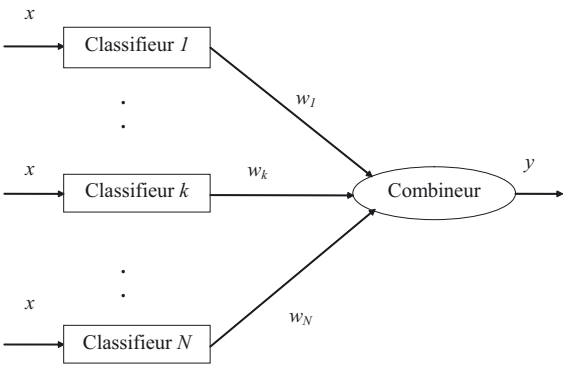



FIGURE 2 Schéma global de la combinaison parallèle de classifieurs. *Global diagram of the parallel combination of the classifiers.*

### 4.1. Hypothèses

Afin de rendre l'application plus cohérente avec les fondements théoriques de la méthode de combinaison des classifieurs, les trois hypothèses suivantes sont supposées vérifiées dans notre cas (Chitroub *et al.*, 2000, 2001a).

Dans le premier cas, nous nous détachons complètement des caractéristiques internes des classifieurs à combiner. Tout ce qui nous intéresse dans un classifieur est la sortie qu'il fournit et non la manière dont il la calcule. Il sera donc considéré comme une boîte noire. De ce fait, la méthode proposée est générale et applicable à tout type de classifieur.

Dans le second cas, nous supposons que les classifieurs sont statistiquement indépendants. L'indépendance considérée ici est l'indépendance conditionnelle par rapport aux classes et non pas l'indépendance non conditionnelle (Chitroub *et al.*, 2001a). En fait, le nombre de classes dans l'application est un paramètre connu pour tous les classifieurs et les paramètres statistiques des classes sont estimés en utilisant la même base d'apprentissage pour tous les classifieurs. Ce qui différencie les classifieurs est la classe affectée à chaque pixel de l'image. Par conséquent, il est plus logique de considérer que les classifieurs sont indépendants par rapport aux classes.

Dans le troisième cas, la combinaison est complètement insensible aux échelles de sorties des classifieurs. La seule chose qui importe est l'estimation des vraisemblances des sorties des classifieurs, ce qui est indépendant des valeurs des sorties.

### 4.2. Méthodologie suivie

Supposons qu'il y ait $N$ classifieurs $Cl_k$. Chaque classifieur $k$ reçoit la même forme $x$ (pixel de l'image à classifier). Soit $\Omega$ l'ensemble fini de toutes les hypothèses (évidences ou classes $w$) possibles et $2^{\Omega}$ l'ensemble des sous-ensembles de $\Omega$. La théorie de l'évidence est complètement caractérisée par une fonction appelée fonction de masse : $m : 2^{\Omega} \rightarrow [0,1]$ telle que :

$$m(\varnothing) = 0 \text{ et } \sum_{A \subseteq \Omega} m(A) = 1.$$

Sa valeur exprime le degré de l'évidence associée à l'ensemble $A$, appelé aussi élément focal, celui-ci ne peut être associé à aucun sous-ensemble particulier de $A$. À chaque fonction de masse est associée une mesure de croyance :

$$\text{Bel (A)} = \sum_{B \subset A} m(B).$$

Le combineur considère la réponse d'un classifieur comme une évidence sur la vraie classe du pixel $x$. Si la réponse est un rejet, on dira que cette évidence soutient complètement l'ensemble $\Omega$, mais ne soutient aucun de ses sous-ensembles,

c'est-à-dire, $m_k(\Omega) = 1$ et $m_k(A) = 0$, $\forall A \subset \Omega$. Si la réponse n'est pas un rejet, c'est-à-dire, $w_{jk}$, le classifieur soutient la proposition $x \in w_{ij}$.

Soit $\tau_{rec}^k$, $\tau_{err}^k$ et $\tau_{rej}^k$, respectivement les taux de reconnaissance, d'erreur et de rejet du classifieur $k$. Supposons que la réponse du classifieur $k$ est correcte avec une confiance $\tau_{rej}^k$, qu'elle est fausse avec une confiance $\tau_{err}^k$ et, comme la réponse de ce classifieur n'indique rien sur les autres classes, tout le reste de la confiance est donné à l'ensemble $\Omega$ , soit :

$$m_k = (\{w_{jk}\}) = \tau_{rec}^k \quad (1)$$

$$m_k = (\{\overline{w_{jk}}\}) = \tau_{err}^k, \text{ avec } m_k = (\{w_{jk}\}) = \tau_{rec}^k \quad (2)$$

$$m_k(\Omega) = \tau_{rej}^k, \text{ et } m_k(A) = 0, \forall A \subset \Omega \quad (3)$$

Nous estimons les valeurs de ces taux à partir de la matrice de confusion $C^k$ du classifieur $k$. Cette dernière est calculée à partir des résultats de classification obtenus par le classifieur sur une base de test. Un élément de cette matrice $c_{ij}^k$ représente le nombre de pixels appartenant à la classe $w_i$ et pour lesquels le classifieur $k$ a répondu $w_j$ :

$$c_{ij}^k = |\{x | x \in w_i, Cl_k(x) = w_{jk}\}|, i = 0,1,\ldots, M \quad (4)$$

où $M$ représente le nombre de classes. Lorsque l'indice $j$ prend la valeur 0, cela signifie que le classifieur a la possibilité de donner au pixel l'étiquette de la classe de rejet $w_0$ s'il considère que les informations mises à sa disposition ne lui permettent pas de donner un résultat fiable. Dans le cas où le résultat du classifieur n'aurait pas une classe de rejet, les éléments de la colonne $j = 0$ de la matrice $C^k$ seront nuls. L'estimation des différents taux est alors donnée par :

$$\tau_{rec}^k = \frac{\sum_{i=1}^{M} c_{ii}^k}{\sum_{i=1}^{M}\sum_{j=0}^{M} c_{ij}^k}, \tau_{err}^k = \frac{\sum_{i=1}^{M}\sum_{j=0, j\neq i}^{M} c_{ij}^k}{\sum_{i=1}^{M}\sum_{j=0}^{M} c_{ij}^k}, \tau_{rej}^k = \frac{\sum_{i=1}^{M} c_{i0}^k}{\sum_{i=1}^{M}\sum_{j=0}^{M} c_{ij}^k} \quad (5)$$

Pour obtenir une attribution de masse qui contient toutes les évidences, il faut combiner les N attributions de masse mk associées aux classifieurs Clk. Pour cela, on utilise la règle de combinaison de Dempster (Shafer, 1976) qui exige que les évidences soient indépendantes. Pour cela aussi, il faut que les classifieurs soient statistiquement indépendants conditionnellement aux classes.

Le processus de combinaison des évidences en utilisant la règle de Dempster s'effectue en deux étapes (figure 3). Chaque étape combine un nombre restreint d'évidences. La combinaison dans une deuxième étape est effectuée sur les évidences résultantes.

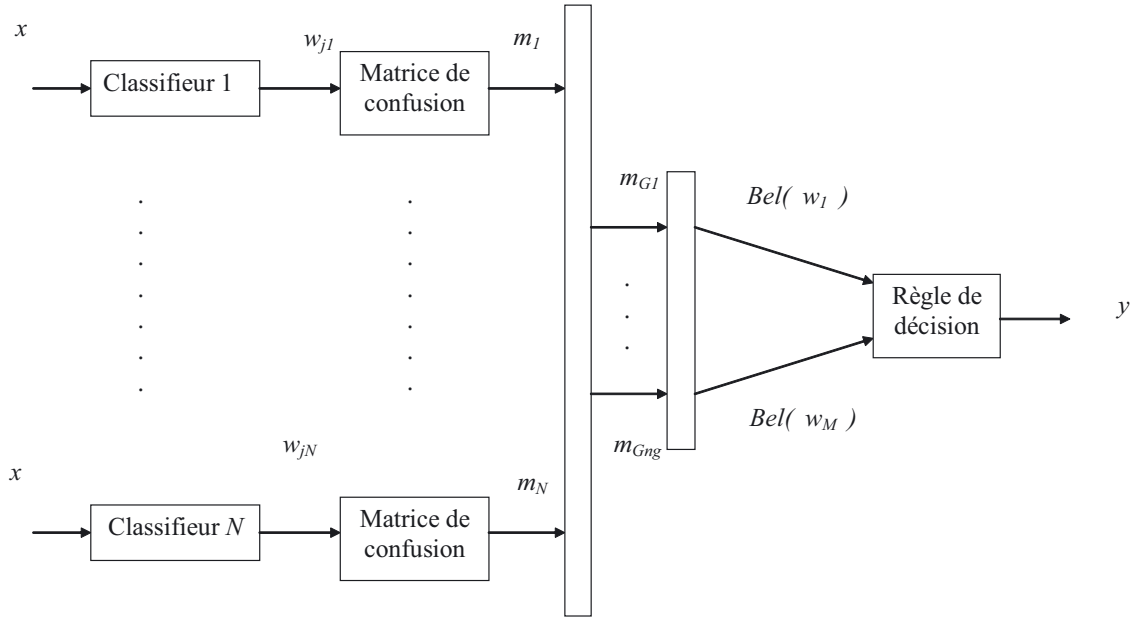



FIGURE 3 Étapes de combinaison de classifieurs en utilisant la théorie de l'évidence. *Steps of the classifier combination using the evidence theory.*

*4.2.1. Première étape de combinaison*

Dans l'application, l'espace des attributions de masse $m_k$ est restreint aux trois éléments focaux seulement, à savoir : $\{w_j\}$, $\{\overline{w_j}\}$ et Ω. Toute autre hypothèse composée des hypothèses $\{w_j\}$ n'a aucune signification, puisqu'on ne peut pas considérer une classe comme un ensemble de classes de caractéristiques différentes.

La première étape de combinaison consiste donc à répartir les $N$ classifieurs en $N_G$ groupes selon leurs réponses (figure 3). Les classifieurs de chaque groupe ont tous la réponse $w_{gi}$ (affectant le pixel à la même classe), donc leurs fonctions d'attribution de base ont toutes les mêmes focaux, mais avec des valeurs différentes de $m$. Il s'agit donc de substituer les classifieurs de départ par un nombre restreint de nouveaux classifieurs qui ont tous des réponses différentes (affectant le pixel à des classes différentes). Soit $G_i$ un groupe de $p$ classifieurs. Leurs attributions de masse $m_{k1}$, $m_{k2}$, …, $m_{kp}$ ont toutes les trois focaux $\{w_j\}$, $\{\overline{w_j}\}$ et Ω. La masse totale du groupe $G_i$ est telle que : $m_{Gi} = m_{k1} \oplus m_{k2} \oplus \ldots m_{kp}$, où ⊕ est la règle de combinaison de Dempster. Le calcul de $m_{Gi}$ est récursif en utilisant la règle de Dempster à deux évidences telle que :

$$m_1 = m_{k1},\ m_r = m_{r-1} \oplus m_{kr},\quad r = 2,3,\ldots,\mathrm{p},\ m_{Gi} = m_p \tag{6}$$

Notons que, pour combiner deux évidences, la règle de Dempster est telle que :

$$m(A) = (m_1 \oplus m_2)\,(A) = \mathrm{K} \sum_{w_1 \cap w_2 = A} m_1(w_1) \cdot m_2(w_2)$$

$$\text{avec } \mathrm{K} = \left( \sum_{w_1 \cap w_2 \neq \Phi} m_1(w_1) \cdot m_2(w_2) \right)^{-1} \tag{7}$$

Une évidence de la forme $m_i(\Omega) = 1$ n'a aucun effet sur le résultat de la combinaison. En outre, nous considérons que : $0 < \tau_{rec}^k < 1$ et $0 \leq \tau_{err}^k < 1$, quel que soit le classifieur. Cette condition nous assure que les évidences fournies par les classifieurs ne seront pas contradictoires, c'est-à-dire que le dénominateur de (7) n'est pas nul. Une preuve simple est donnée dans Xu *et al*. (1992). Les cas de $\tau_{rec}^k = 1$, $\tau_{err}^k = 1$ et $\tau_{rej}^k = 0$ sont des cas dégénérés qui peuvent être traités à part. L'espace des attributions de masse $m_{Gi}$ est restreint aux trois éléments focaux seulement : $\{w_j\}$, $\{\overline{w_j}\}$ et Ω. Le groupe $G_i$ est considéré comme un classifieur qui a répondu $w_{gi}$ avec $\tau_{rec} = m_{Gi}(\{w_{gi}\})$, $\tau_{err} = m_{Gi}(\{\overline{w_{gi}}\})$ et $\tau_{rejet} = m_{Gi}(\Omega)$.

Dans cette première étape, on change donc les $N_{Cl}$ classifieurs en $N_G$ classifieurs qui ont tous des réponses différentes, telles que :

$$w_{g_1} \neq w_{g_2} \neq \ldots \neq w_{g_{\mathrm{NG}}}.$$

*4.2.2. Deuxième étape de combinaison*

La deuxième étape du processus de combinaison consiste à fusionner les évidences des classes des nouveaux groupes de classifieurs $N_G$ (figure 3) tel que : $m = m_{Gi} \oplus m_{G1} \oplus \ldots \oplus m_{GNG}$. Comme les $N_G$ groupes de classifieurs donnent des classes différentes les unes des autres, la combinaison des évidences, c'est-à-dire le calcul de $m$, devient très lourd avec la règle de Dempster. Afin de réduire le temps de calcul des combinaisons des fonctions de croyance, des simplifications ont été introduites dans le processus de combinaison en s'inspirant des résultats théoriques des travaux publiés dans la communauté d'intelligence artificielle (Xu *et al.*, 1992 ; Barnet, 1991). Sachant que $N_G \leq M$ et $N_G \leq N$, nous obtenons des relations simplifiées pour calculer les fonctions de croyance en chacune des classes :

$$a = \sum_{i=1}^{N_G} \frac{m_{Gi}(\{w_{gi}\})}{1 - m_{Gi}(\{w_{gi}\})},\ b = \prod_{i=1}^{N_G} (1 - m_{Gi}(\{w_{gi}\})) \tag{8}$$

$$c = \prod_{i=1}^{N_G} m_{Gi}(\{\overline{w_{gi}}\}),\ F = \begin{cases} (1+a)b - \mathrm{c} & \text{si } N_G = M \\ (1+a)b & \text{si } N_G < M \end{cases} \tag{9}$$

$$Bel\,(\{w_{gi}\}) = \begin{cases} F \cdot \left( \dfrac{m_{Gi}(\{w_{gi}\})}{1 - m_{Gi}(\{w_{gi}\})} \cdot b + \dfrac{m_{Gi}(\{\Omega\})}{m_{Gi}(\{\overline{w_{gi}}\})} \cdot c \right) & \text{si } N_G = M \text{ ou } N_G = M-1,\ i = M \\ F \cdot \left( \dfrac{m_{Gi}(\{w_{gi}\})}{1 - m_{Gi}(\{w_{gi}\})} \cdot b \right) & \text{sinon} \end{cases} \tag{10}$$

$$Bel\,(\{\overline{w_{gi}}\}) = \begin{cases} F \cdot \left( \left( a - \dfrac{m_{Gi}(\{w_{gi}\}) - m_{Gi}(\{\overline{w_{gi}}\})}{1 - m_{Gi}(\{w_{gi}\})} \right) \cdot b - c \right) & \text{si } N_G = M \\ F \cdot \left( a - \dfrac{m_{Gi}(\{w_{gi}\}) - m_{Gi}(\{\overline{w_{gi}}\})}{1 - m_{Gi}(\{w_{gi}\})} \right) \cdot b & \text{si } N_G < M,\ i \leq N_G \\ F \cdot \left( a - \dfrac{m_{Gi}(\{w_{gi}\})}{1 - m_{Gi}(\{w_{gi}\})} \right) \cdot b & \text{sinon} \end{cases} \quad (11)$$

#### 4.2.3. Règle de décision

Les fonctions de croyance des réponses des $N_G$ classifieurs étant calculées, une règle de décision appropriée est utilisée pour reclassifier l'image. La règle tient compte des informations portées après combinaison par les fonctions de croyance des classes ainsi que par les fonctions de non-croyance des classes, c'est-à-dire par $Bel\,(\{w_{gi}\})$ et $Bel\,(\{\overline{w_{gi}}\})$.

Soit :

$$Bel_{nette}\,(w_{gi}) = Bel\,(\{w_{gi}\}) - Bel\,(\{\overline{w_{gi}}\}),$$

la croyance nette en classe $w_{gi}$ du groupe $g_i$. La règle utilisée pour la classification finale est alors :

$$y = \left\{ \begin{array}{l} w_j \text{ si } Bel_{nette}\,(\{w_j\}) = \max\limits_{w_i \in \Omega} Bel_{nette}\,(\{w_i\}) \geq \alpha,\ 0 < \alpha < 1 \\ \\ w_0 \text{ sinon} \end{array} \right\} \quad (12)$$

Le paramètre $\alpha$ est le seuil de rejet calculé en fonction du nombre de classes possibles.

#### 4.2.4. Exemple numérique

Afin de présenter, d'une manière explicite, les calculs des formules mathématiques de la méthodologie proposée, on donne un exemple d'une image comprenant trois classes thématiques : eau (C1), végétation (C2) et sol (C3). Les deux classifieurs à combiner donnent deux résultats différents (figure 4). Le conflit entre les deux classifieurs réside dans le fait que le premier classifieur considère la classe C3 comme étant la classe C2 alors que le deuxième classifieur considère la classe C2 comme étant la classe C3.

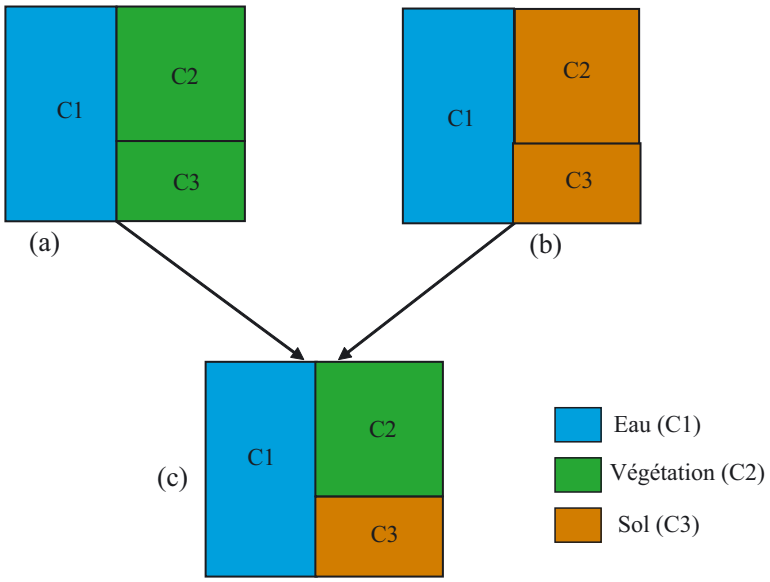



FIGURE 4 Exemple numérique : (a) Résultat du premier classifieur, (b) Résultat du deuxième classifieur, (c) Résultat de la combinaison des deux classifieurs. *Numerical example : (a) Result of the first classifier, (b) Result of the second classifier, (c) Result of the combination of the two classifiers.*

Donc, l'ensemble fini de toutes les hypothèses (évidences ou classes) est Ω = {eau, végétation, sol}. Les éléments focaux possibles de Ω sont : {eau}, {végétation}, {sol}, {eau, végétation}, {eau, sol}, {végétation, sol} et {eau, végétation, sol}. Le sous-ensemble {végétation, sol} signifie que le pixel peut être végétation ou sol. Donc, la masse affectée à ce sous-ensemble caractérise l'ignorance sur l'appartenance du pixel à la classe {végétation} ou à la classe {sol}. Puisque les deux classifieurs ne considèrent pas les hypothèses {eau, végétation} et {eau, sol}, la masse attribuée à chacun de ces deux éléments focaux est donc nulle. La masse attribuée à Ω représente la portion de masse qu'on n'arrive pas à attribuer à aucun des sous-ensembles de Ω : elle caractérise donc l'ignorance globale.

Ainsi, les éléments focaux considérés dans le processus de la combinaison sont les suivants : {eau}, {végétation}, {sol}, {végétation, sol} et {eau, végétation, sol}. Les masses attribuées à ces éléments focaux, pour les deux classifieurs, sont calculées en utilisant les expressions (1), (2) et (3) (tableau 1).

La combinaison des masses des éléments focaux consiste à distribuer les masses, qui ont été affectées aux unions de classes, sur les classes singletons {eau}, {végétation} et {sol}. La combinaison est effectuée en utilisant la règle de Dempster (7). Les nouvelles masses ainsi obtenues sont mentionnées sur le tableau 2. Ces nouvelles masses sont utilisées pour calculer les fonctions de croyance associées selon les expressions (8), (9), (10) et (11). Ces fonctions de croyance sont utilisées ensuite dans la règle de décision (12) pour reclassifier l'image. Dans l'image de la combinaison (figure 4), la distinction entre les classes C2 et C3 est obtenue grâce à la redistribution des masses qui a été effectuée à travers la combinaison.

TABLEAU 1 Les masses attribuées aux éléments focaux, pour les deux classifieurs, calculées en utilisant les expressions (1), (2) et (3). *Masses allocated to the focal elements of the two classifiers calculated by using the expressions (1), (2) and (3).*

| | Masse de l'élément focal dans le premier classifieur $m_1(.)$ | Masse de l'élément focal dans le deuxième classifieur $m_2(.)$ |
|---|---|---|
| Eau | 0,35 | 0,35 |
| Végétation | 0,20 | 0,05 |
| Sol | 0,01 | 0,15 |
| Végétation,sol | 0,34 | 0,35 |
| $\Omega$ | 0,10 | 0,10 |

TABLEAU 2 Redistributions des masses des unions des classes sur les classes singletons {eau}, {végétation} et {sol} après la combinaison des masses des éléments focaux des deux classifieurs données sur le tableau 1, en utilisant la règle de Dempster (7). *Redistribution of the masses of the unions of the classes on the singleton classes {water}, {vegetation} and {ground} after the combination of the focal element masses of the two classifiers given in table 1, by using the Dempster rule (7).*

| | $M_2$({eau}) | $m_2$({végétation}) | $m_2$({sol}) | $m_2$({végétation, sol}) | $m_2$({$\Omega$}) |
|---|---|---|---|---|---|
| $m_1$({eau}) | 1 | 0 | 0 | 0 | 0 |
| $m_1$({végétation}) | 0 | 0,55 | 0,13 | 0,27 | 0,05 |
| $m_1$({sol}) | 0 | 0,15 | 0,50 | 0,30 | 0,05 |
| $m_1$({végétation, sol}) | 0 | 0,25 | 0,20 | 0,35 | 0,20 |
| $m_1$({$\Omega$}) | 0 | 0,20 | 0,20 | 0,40 | 0,10 |

## 5. RÉSULTATS EXPÉRIMENTAUX

Trois expériences ont été effectuées pour tester et évaluer la méthode de combinaison de classifieurs en utilisant la théorie de l'évidence proposée ici.

### *5.1. Première expérience : utilisation des images simulées*

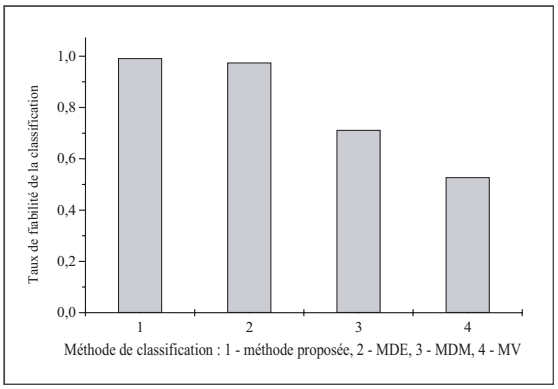
L'image simulée bruitée a été classifiée par trois classifieurs différents (figure 1), à savoir (Chitroub, 1994) : le classifieur de maximum de vraisemblance (MV), le classifieur de minimum de distance de Mahalanobis (MDM) et le classifieur de minimum de distance euclidienne (MDE). Le résultat de MDE est le plus précis et l'image correspondante est la moins bruitée. La même remarque peut être formulée pour le résultat de MDM par rapport au résultat de MV. L'image de ce dernier est très dégradée et loin de la réalité de terrain.

Nous avons utilisé la même base d'échantillons d'apprentissage pour estimer les paramètres du modèle de décision de chaque classifieur. En effet, dans cette première expérience, notre but est de prouver la robustesse de la méthode vis-à-vis des classifieurs moins performants. Donc, nous pouvons justifier les résultats des trois classifieurs par le degré de sensibilité de chacun d'eux à la taille et à la qualité de la base d'apprentissage (Chitroub, 1994). Sur l'image résultante de la combinaison de trois classifieurs (figure 1), nous constatons une amélioration portée par l'image de combinaison, avec quelques points de rejet, en comparaison avec les images des trois classifieurs.

Il y a moins de pixels mal classifiés. Bien que l'image la plus dégradée soit incluse dans le processus de combinaison, l'image résultante de combinaison est moins bruitée que le meilleur résultat des trois classifieurs. Sur la figure 5, on donne le taux de fiabilité des trois classifieurs et celui du résultat de leur combinaison. Ce taux permet de quantifier et de mesurer la fiabilité de la classification. Il est défini par :

$$fiabilité = \frac{\tau_{rec}}{(1 - \tau_{rejet})} \qquad (13)$$

où $\tau_{rec}$ et $\tau_{rejet}$ sont, respectivement, le taux de reconnaissance et le taux de rejet du classifieur. Le taux de fiabilité de la classification après combinaison est supérieur aux taux des trois classifieurs. Notons que la matrice de confusion utilisée dans cette expérience est calculée à partir de l'image de réalité de terrain (figure 1).




MDE = Minimum de distance euclidienne; MDM = Minimum de distance de Mahalanobis; MV = Maximum de vraisemblance

FIGURE 5 Taux de fiabilité des trois classifieurs et celui du résultat de leur combinaison (image simulée bruitée). *Reliability rates of the three classifiers and that of the result of their combination (noised simulated image).*

### *5.2. Deuxième expérience : utilisation d'une image multibande de télédétection*

Il est possible de considérer les trois bandes spectrales de HRV (XS1, XS2 et XS3) comme des images multicapteurs ou encore des images multisources du fait que chaque bande nous fournit des informations différentes ou complémentaires par rapport aux informations fournies par les deux autres bandes. À cet effet, nous pouvons qualifier cette expérience comme étant une amélioration d'une classification multisource.

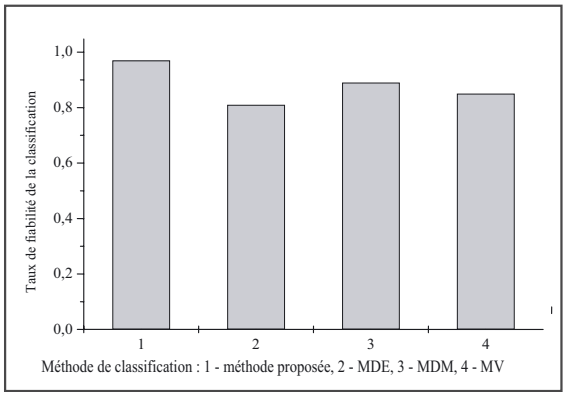
Les trois bandes du capteur ont été utilisées comme entrée pour les trois classifieurs MV, MDM et MDE. La même conclusion que dans le cas de l'image simulée peut être formulée sur la précision des images classifiées obtenues.

Le but de cette deuxième expérience est de faire ressortir la robustesse de la méthode proposée et de pouvoir fonctionner correctement dans des situations où l'image de référence caractérisant la réalité de l'image n'est pas disponible. En effet, les matrices de confusion des classifieurs utilisées dans le processus de combinaison sont calculées à partir des trois images classifiées à combiner et non pas en utilisant l'image de réalité de terrain, et ceci de la manière suivante. Chacune des images classifiées impliquées dans la combinaison est prise, à tour de rôle, comme image de référence et les matrices de confusion des autres images sont construites à partir de cette image de référence. La matrice de confusion de chaque classifieur utilisée dans la combinaison est la matrice moyenne des matrices de confusion calculées en utilisant les autres classifieurs comme références.

La combinaison de trois classifieurs a amélioré le résultat final de la classification. Puisque, dans la

littérature, il n'y a pas assez de critères d'évaluation de classification en absence de réalité de terrain, la définition de Haralick (1979) d'une bonne segmentation a été utilisée. Ceci consiste à calculer la moyenne des taux de fiabilité calculés dans plusieurs zones homogènes. Le taux moyen de la combinaison est supérieur aux taux moyens des classifieurs (figure 6).

Ainsi, en utilisant la théorie de l'évidence, la combinaison des classifieurs a permis d'obtenir une classification plus précise, dans les deux expériences, et de prouver de ce fait sa robustesse et son efficacité.




MDE = Minimum de distance euclidienne; MDM = Minimum de distance de Mahalanobis; MV = Maximum de vraisemblance

FIGURE 6 Taux de fiabilité des trois classifieurs et celui du résultat de leur combinaison (image de Blida). *Reliability rates of the three classifiers and that of the result of their combination (image of Blida).*

### *5.3. Troisième expérience : utilisation des images multidates*

Tout d'abord, il faut noter que plusieurs méthodes et approches de détection des changements ont été proposées dans la littérature et que cet axe de recherche est toujours une voie ouverte dans la communauté de traitement d'images de télédétection (Deer, 1998 ; Almutairi, 2000).

Le but de cette expérience est de montrer la possibilité d'utiliser la méthode de combinaison de classifieurs proposée pour résoudre le problème de détection des changements dans les images de télédétection. Le jeu de données dont nous disposons (voir section 2) ne permet pas d'évaluer d'une manière précise les résultats obtenus, en raison d'absence des données de réalité de terrain pour les deux dates de prise de vue. De plus, des difficultés ont été rencontrées dans la correction géométrique effectuée sur les images. En fait, la sélection des points d'appui était une tâche très fastidieuse à cause de présence des zones cachées par les nuages et l'importance de la surface de la mer.

L'approche de détection des changements en utilisant la combinaison des classifieurs consiste à classifier séparément les deux ensembles des images multidates (images HRV de 1986 et de 1991) en utilisant le même type de classifieur. Le classifieur non dirigé K-moyennes a été utilisé afin d'éviter le problème difficile de détection du nombre réel de classes existantes dans l'image ainsi que le problème d'extraction des échantillons représentatifs relatifs aux classes (Davé and Krishnapuram, 1997 ; Chitroub *et al.*, 1999, 2000). Sept classes ont été choisies pour le classifieur K-moyennes. Ce choix du nombre initial de classes est justifié par le fait que l'image a subi des changements pendant la période qui sépare les deux dates de prise de vue. Puisque nous ne disposons pas d'informations précises et fiables sur l'état de surface de l'image, nous avons supposé que les thèmes des classes sans changement soient ceux décrits à la section 2, à savoir : la végétation, les zones agricoles, la mer, les zones urbaines, les constructions, le sol nu et les routes. Les résultats du classifieur sont utilisés comme des entrées du combineur.

Le résultat de la combinaison peut être interprété comme une détection des changements uniquement pour les pixels ayant trois valeurs différentes dans les trois images classifiées (les sorties du classifieur K-moyennes en utilisant les deux ensembles des images et la sortie du combineur). Les pixels ayant seulement deux valeurs différentes dans les trois images classifiées ne sont pas considérés comme des pixels de changements mais plutôt comme des informations conflictuelles entre les deux classifieurs. Ainsi, le résultat de la combinaison, présenté sur la figure 7, est différent des deux résultats du classifieur en utilisant les bandes spectrales (XS1, XS2, XS3) prises respectivement en 1986 et en 1991. Dans l'image de la combinaison (figure 7), nous avons attribué : 1) la couleur blanche pour les classes de végétation, de zones agricoles et de la mer ; 2) la couleur noire pour les classes des zones urbaines, de constructions, de sol nu et des routes. Les cinq classes restantes sont considérées comme des classes de changements ou d'informations conflictuelles entre les deux classifieurs. Nous avons attribué à ces classes les couleurs suivantes : jaune, orange, verte, bleu clair et bleue.

Afin de faire ressortir les zones de changements et les zones d'informations conflictuelles, à partir du résultat de la combinaison, nous avons créé une image des zones de changements, qui correspond aux pixels ayant des valeurs différentes dans les trois images classifiées (couleur noire) et des zones d'informations conflictuelles entre les deux résultats du classifieur, qui correspond aux pixels ayant des valeurs différentes dans deux images classifiées seulement (couleur bleue). Sur la figure 8, on

présente l'image des zones de changements et d'informations conflictuelles obtenue. Sous la réserve concernant la nature du climat pendant les périodes de prise de vue des deux ensembles d'images, nous pouvons dire que les zones agricoles et végétatives de l'image à l'est d'Alger ont subi une dégradation en faveur des constructions urbaines anarchiques et du sol nu. Nous pourrons mieux interpréter les résultats si les cartes de réalité de terrain ainsi que des informations concernant la nature du climat pendant les périodes des dates de prise de vue seront disponibles.

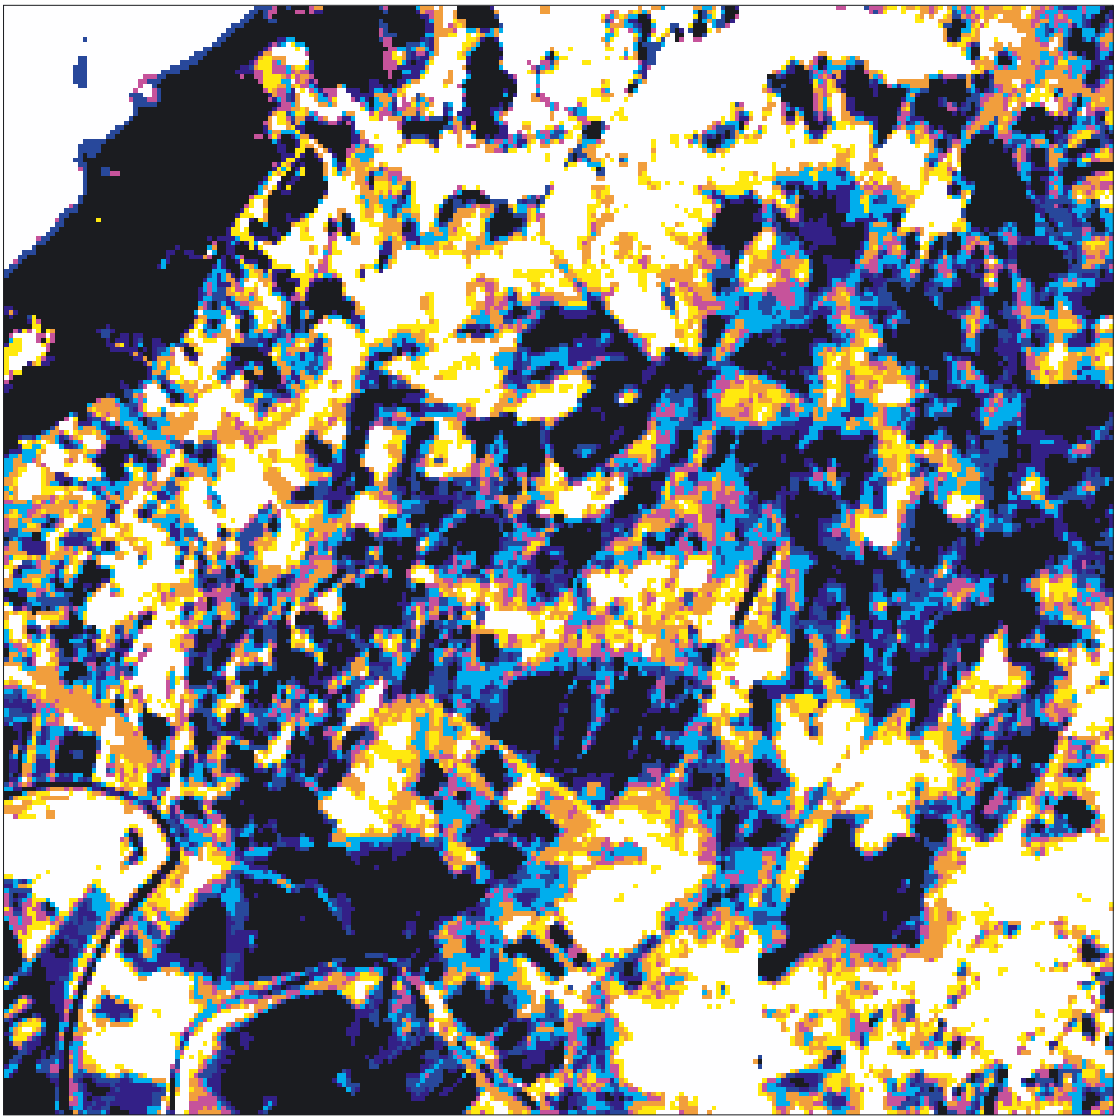



FIGURE 7 Résultat de la combinaison de deux classifieurs (image à l'est d'Alger). *Result of the combination of two classifiers (image in the east of Algiers).*

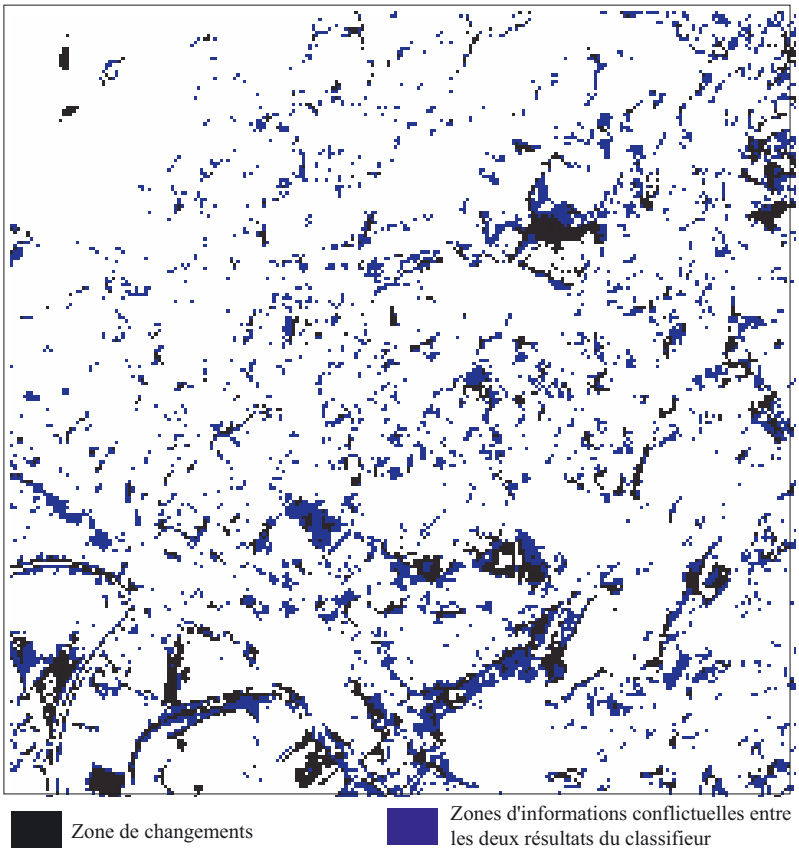



FIGURE 8 Image des zones de changements et des zones d'informations conflictuelles, entre les deux classifieurs, obtenue à partir de l'image de la combinaison de la figure 7. *Image of the change zones and the conflict zones, between the two classifiers, obtained from the image of the combination presented in figure 7.*

## 6. CONCLUSION

La classification d'images de télédétection est un problème mal posé en raison de l'insuffisance d'informations a priori déterministes et fiables sur l'état et la nature de la formation de l'image à l'instant de prise de vue. L'originalité du travail d'amélioration de la classification d'images de télédétection présenté réside dans le fait qu'une interprétation plus cohérente et plus précise de l'image prise par les capteurs satellitaires est obtenue. L'incertitude qui y est associée est diminuée.

Une méthode de combinaison de classifieurs basée sur le principe de combinaison parallèle des systèmes répartis (classifieurs) en utilisant la théorie de l'évidence est alors proposée. Le but est de traiter les sorties des classifieurs en ignorant complètement les caractéristiques internes de ces derniers. La méthode est donc générale et applicable à tout type de classifieur. Elle cumule les avantages de chaque classifieur sans en cumuler les inconvénients. Selon l'application envisagée, les images d'entrée des classifieurs peuvent être de sources différentes ou multidates. La méthode surmonte les inconvénients des méthodes de classification d'images de télédétection développées dans la littérature. Nous avons utilisé le taux de fiabilité de la classification comme critère d'évaluation. Les résultats obtenus à l'aide des images simulées et réelles de télédétection montrent que la méthode proposée donne de meilleurs résultats en comparaison avec celles des classifieurs considérés séparément.

Ainsi, la méthode proposée constitue un outil puissant pour plusieurs applications de télédétection spatiale. Cependant, elle n'a pas le mécanisme qui permet d'intégrer des informations de nature différentes. En fait, la méthode ne peut pas manipuler des données auxiliaires de nature différentes telles que cartes thématiques numériques, mesures expérimentales, statistiques sur les classes de l'image à classifier, etc. Ces types de données sont impossibles à intégrer dans le

processus de combinaison dont la modélisation des entrées du combineur est une étape préliminaire et essentielle. De plus, on ne sait pas d'avance si ces données auxiliaires peuvent aider ou non à la prise de décision plus précise, d'où l'idée de transformer le combineur à un système expert qui a le mécanisme d'intégrer aisément des données de nature différentes, sans qu'elles soient modélisées, et aide à la prise de décision plus exacte. La nouveauté réside dans un aspect de raisonnement particulier qui consiste à utiliser la théorie d'évidence dans la gestion d'incertitudes existantes entre ces données de nature différentes. Ceci fait l'objet d'un futur travail qui sera soumis prochainement pour publication.

### *Références*


Almutairi, A. (2000) Monitoring land cover change detection in an arid urban environment : A comparison of change detection techniques. Mémoire de maîtrise, University of West Virginia, Morgantown, 88 p.

Appriou, A. (1991) Probabilité et incertitude en fusion de données multi-senseurs. Revue Scientifique et Technique de la Défense, vol. 1, p. 27-40.

Barnett, J.A. (1991) Calculating Dempster-Shafer plausibility. IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 13, nº 6, p. 868-875.

Benediktsson, J.A. and Landgrebe, D.A. (1999) Introduction. IEEE Transactions on Geoscience and Remote Sensing, vol. 37, p. 1187.

Bonnin, P., Douarin, H. and Pissaloux, E. (1995) A new way of image data fusion: the multi-spectral co-operative segmentation. IEEE International Conference on Image Processing (ICIP'95), Washington, vol. 3, p. 572-575.

Chibani, Y. and Nemmour, H. (2003) Kalman Filtering as a Multilayer Perceptron Training Algorithm for Detection Changes in Remotely Sensed Imagery. IEEE International Geoscience and Remote Sensing Symposium (IGARSS'03), 21-25 juillet, 2003, Toulouse (France), p. 4101-4103.

Chitroub, S. (1994) Implémentation d'un Processus d'Analyse et de Classification d'Images Satellitaires. Application à la Caractérisation des États de Surface. Thèse de Magister, Numéro d'ordre 03/94-M/EL, Institut d'électronique, Université des sciences et technologie Houari Boumediene, Alger, 190 p.

Chitroub, S., Houacine, A. and Sansal, B. (1999) Robust optimal fuzzy clustering algorithm applicable to multispectral and polarimetric synthetic aperture radar images. Proceedings of SPIE, EUROPTO Series, Image and Signal Processing for Remote Sensing Conference, 21-25 septembre, 1999, Florence (Italie), vol. 3871, p. 325-336.

Chitroub, S., Houacine, A. and Sansal, B. (2000) Bayesian combination method of classifiers for cluster validation problem. Proceedings of SPIE, EUROPTO Series, Image and Signal Processing for Remote Sensing Conference, 21-25 septembre, 2000, Barcelone (Espagne), vol. 3501, p. 325-336.

Chitroub, S., Houacine, A. et Sansal, B. (2001a) Fusion Bayésienne des classifieurs pour une meilleure classification des scènes imagées. Proceedings of International Symposium on Programming and Systems (ISPS'01), 12-14 mai, 2001, Algier (Algerie), p. 69-73.

Chitroub, S., Houacine, A. et Sansal, B. (2001b) Fusion de classifieurs en utilisant la théorie de l'évidence pour l'amélioration de la classification d'images. Comptes rendus du 18e Colloque sur le traitement du signal et des images (GRETSI'01), 13-16 septembre, 2001, Toulouse (France), p. 115-118.

Chitroub, S., Houacine, A. and Sansal, B. (2001c) Evidential reasoning-based classification method for remotely sensed images. Proceedings of SPIE, Image and Signal Processing for Remote Sensing Conference, 18-21 septembre, 2001, Toulouse (France), vol. 4541, p. 340-351.

Chitroub, S., Houacine, A. et Sansal, B. (2002) Fusion de classifieurs, une approche pour l'amélioration de la classification d'images. Comptes rendus du 6e Colloque africain sur la recherche en informatique (CARI'02), 14-17 octobre 2002, Yaoundé (Cameroun), p. 309-316.

Cleynenbreugel, J., Osinga, S.A., Fierens, F., Suetens, P. and Oosterlinck, A. (1991) Road extraction from multi-temporel satellite images by an evidential reasoning appraoch. Pattern Recognition Letters, vol. 12, p. 371-380.

Davé, R.N. and Krishnapuram, R. (1997) Robust clustering methods: a unified view. IEEE Transactions on Fuzzy Systems, vol. 5, nº 2, p. 270-292.

Deer, P. (1998) Digital change detection in remotely sensed imagery using fuzzy set theory. Thèse de doctorat, Department of Geography and Department of Computer Science, University of Adelaide (Australie), 270 p.

Harralick, R. M. (1979) Statistical and structural approaches to texture. Proceedings of IEEE, vol. 67, p. 786-804.

Le Hégarat-Mascle, S., Bloch I. and Vidal-Madjar, D. (1997) Application of Dempster-Shafer evidence theory to unsupervised classification in multisource remote sensing. IEEE Transactions on Geosciences and Remote Sensing, vol. 35, n° 4, p. 1018-1030.

Kanal, L.N. (1993) On pattern, categories, and alternate realities. Pattern Recognition Letters, vol. 14, p. 241-255.

Kimura, F. and Shridhar, M. (1991) Handwritten numerical recognition based on multiple algorithms. Pattern Recognition, vol. 24, n° 10, p. 969-983.

Minsky, M. (1991) Logical versus analogical, or symbolic versus connectionist, or neat versus scruffy. Artificial Intelligence Magazine, vol. 12, n° 2, p. 34-51.

Moobeb, B. (1996) Combinaison de Classifieurs, une Nouvelle Approche. Thèse de doctorat, École polytechnique LIX, Université de Paris Sud, UFR scientifique d'Orsay, Paris, 250 p.

Peddle, D.R. and Franklin, S.E. (1992) Multisource evidential classification of surface cover and frozen ground. International Journal of Remote Sensing, vol. 13, nº 17, p. 3375-3380.

Petrou, A. and Stassopoulou, A. (1999) Advanced techniques for fusion of information in remote sensing an overview. Proceedings of SPIE, EUROPTO Series, Image and Signal Processing for Remote Sensing Conference, 22-24 septembre, 1999, Florence (Italie), vol. 3871, p. 264-275.

Shafer, G. (1976) A Mathematical Theory of Evidence. Princeton University Press, Princeton (NJ), 312 p.

Rosenberger, C. and Chehdi, K. (2000) Genetic Fusion : Application to multi-components image segmentation. IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP 2000), 5-9 juin, 2000, Istanboul (Turkie), vol. 3, p. 2223-2226.

Tikhonov, A.N. and Arsenin, V.Y. (1977) Solutions of Ill-Posed Problems. Winston and Sons, Washington D.C., 272 p.

Srinivasan, A. and Richards, J.A. (1990) Knowledge-based techniques for multisource classification. Internationnal Journal of Remote Sensing, vol. 11, n° 3, p. 505-525.

Xu, L., Krzyzak, A. and Suen, C. (1992) Methods of combining multiple classifiers and their applications to handwriting recognition. IEEE Transactions on Systems, Man, and Cybernetics, vol. 22, n° 3, p. 418-435.

Wald, L.A. (1998) European proposal for terms of reference in data fusion. International Archives of Photogrammetry and Remote Sensing, vol. XXXII, Part 7, p. 651-654.