Télédétection, 2006, vol. 6, n° 4, p. 263-275
© 2006 CONTEMPORARY PUBLISHING INTERNATIONAL
Publié sous l'enseigne *Éditions Scientifiques GB*

ÉVALUATION DE LA MÉTHODE DES HISTOGRAMMES DE LA SOMME ET DE LA DIFFÉRENCE PAR CLASSIFICATION NEURONALE : APPLICATION AUX IMAGES DE HRV (XS) DE SPOT

Tahar IFTENE et Khalifa DJERRIRI

Centre National des Techniques Spatiales (CNTS),
B.P. 13, Arzew 31200, Oran, Algérie.
Téléphone : (213) 41 47 25 79 ; télécopieur : (213) 41 47 36 65 ;
courriel : tiftene@yahoo.fr ; djerriri@yahoo.fr

Soumis le 19 juillet 2005 ; révisé le 16 février 2006 ; accepté le 1er décembre 2006

Les méthodes de classification des images de télédétection les plus fréquemment utilisées n'introduisent que des informations d'ordre spectral et, dans les résultats obtenus par ces méthodes, se pose souvent le problème des confusions entre les différentes classes thématiques. Cela vient du fait que la réponse spectrale d'un objet n'est pas toujours une caractéristique suffisante. L'objectif de cet article est de montrer tant l'apport d'intégration des informations texturales afin d'améliorer les résultats obtenus par les classificateurs purement spectraux que d'évaluer la méthode de caractérisation de texture de l'algorithme SDH (histogrammes de la somme et de la différence) par rapport à celle de la matrice de cooccurrence. Pour cela, un classificateur neuronal de type perceptron multicouche a été choisi pour les différentes approches traitées à l'aide des images multibandes de HRV (XS) de SPOT de haute résolution spatiale de la région d'Oran, en Algérie. Les résultats montrent bien l'amélioration du taux de bonne classification obtenu dans le cas de l'intégration de paramètres texturaux (92,9 % pour la méthode de la matrice de cooccurrence et 94,6 % pour la méthode de l'algorithme SDH) par rapport à la classification spectrale (88,4 %). Cette amélioration est plus importante dans le cas de la méthode de l'algorithme SDH qui présente, en plus, de bonnes performances en matière de mémoire informatique utilisée et de temps de calcul.

Mots clés : Matrice de cooccurrence, histogrammes de la somme et de la différence, image satellitaire, classificateur neuronal, texture.

EVALUATION OF THE SUM AND DIFFERENCE HISTOGRAMS METHOD BY NEURAL CLASSIFICATION : APPLICATION TO SPOT HRV (XS) IMAGES

The most widely used methods for the classification of remote sensing images introduce only information of a spectral nature and hence the results obtained by these methods often present problems of confusion between the different thematic classes. This is due to the fact that the spectral response of an object is not always a sufficient characteristic. The objective of this work is to show, on the one hand, the contribution of textural information integration in order to improve the results obtained by classifiers using only spectral information and, on the other hand, to evaluate the method of characterization of SDH texture (sum and difference histograms) in relation to the one of the co-occurrence matrix. For this, a multilayer perceptron type neuronal classifier has been chosen for the different approaches processed using high resolution SPOT-XS multispectral images over the Oran region, in Algeria. The results show an improvement of the correct classification rate obtained in the case of the textural parameter integration (92,9 % for the co-occurrence matrix and 94,6 % for the SDH algorithm) in relation to the spectral classification (88,4 %). This improvement is more important in the case of the SDH method, which presents, in addition, good performance in terms of memory and computing time.

Keywords : co-occurrence matrix, sum and difference histograms, satellite images, neural classifier, texture.

1. INTRODUCTION

Les images satellitaires de haute résolution représentent un potentiel important de collection et d'actualisation d'informations géographiques. L'utilisation de ces images dans les dernières décennies s'est multipliée dans de nombreux domaines d'application y compris la classification de l'occupation des terres (Puissant, 2003).

Les méthodes de classifications d'images satellitaires permettent en général une analyse de données en regroupant l'ensemble des pixels formant les images à classifier en classes, de telle sorte que les pixels appartenant à une même classe soient plus semblables entre eux que ceux appartenant à des classes différentes. Ces méthodes n'introduisent souvent que des informations d'ordre spectral, ce qui pose toujours le problème de confusion entre les différentes classes. Cela vient du fait que la réponse spectrale d'un objet n'est pas une caractéristique suffisamment discriminante (Zahzah, 1992).

Entre autres, on a cherché à explorer le potentiel de la texture pour la classification d'images satellitaires. Des résultats probants ont été obtenus avec des images à haute résolution spatiale dans divers domaines de la cartographie du territoire (Bugnet *et al.*, 2003). À cet effet, de nombreuses méthodes de caractérisation de texture ont été proposées. Ces méthodes définissent des paramètres discriminants de la texture en se basant sur des outils statistiques ou de traitement de signal (Coroyer, 1996 ; Tuceryan and Jain, 1998). Haralick et Shanmugam (1973) ont proposé une série de paramètres de texture estimés à partir des matrices de cooccurrence. Bien que précise, cette méthode est lente et requiert beaucoup d'espace de mémoire. En 1986, Unser a proposé une technique alternative

beaucoup plus rapide et moins exigeante en espace de mémoire pour calculer un bon nombre de mesures d'Haralick et Shanmugam sans avoir recours aux matrices de cooccurrence (Unser, 1986 ; Alajarin Martinez-Cabeza-de-Vaca *et al*., 1999 ; Bugnet *et al*., 2003).

Dans cet article, on présente une comparaison entre trois classifications : la première utilise uniquement les canaux spectraux bruts, la seconde combine les canaux spectraux aux nouveaux canaux dérivés de la matrice de cooccurrence et la troisième combine toujours les canaux spectraux à ceux dérivés de la méthode d'analyse texturale d'Unser. À cette fin, on utilise un classificateur neuronal de type perceptron multicouche (Djerriri, 2004).

2. SITE D'ÉTUDE

La région d'Oran, située à 400 km à l'ouest d'Alger (figure 1), a été prise comme zone test pour la variété des thèmes en présence (eau, forêt, zones urbaines, céréaliculture, etc.) et son relief relativement accidenté. Elle constitue donc un bon exemple pour tester l'efficacité d'intégration des données texturales afin d'éviter les confusions souvent rencontrées dans les classifications purement spectrales.

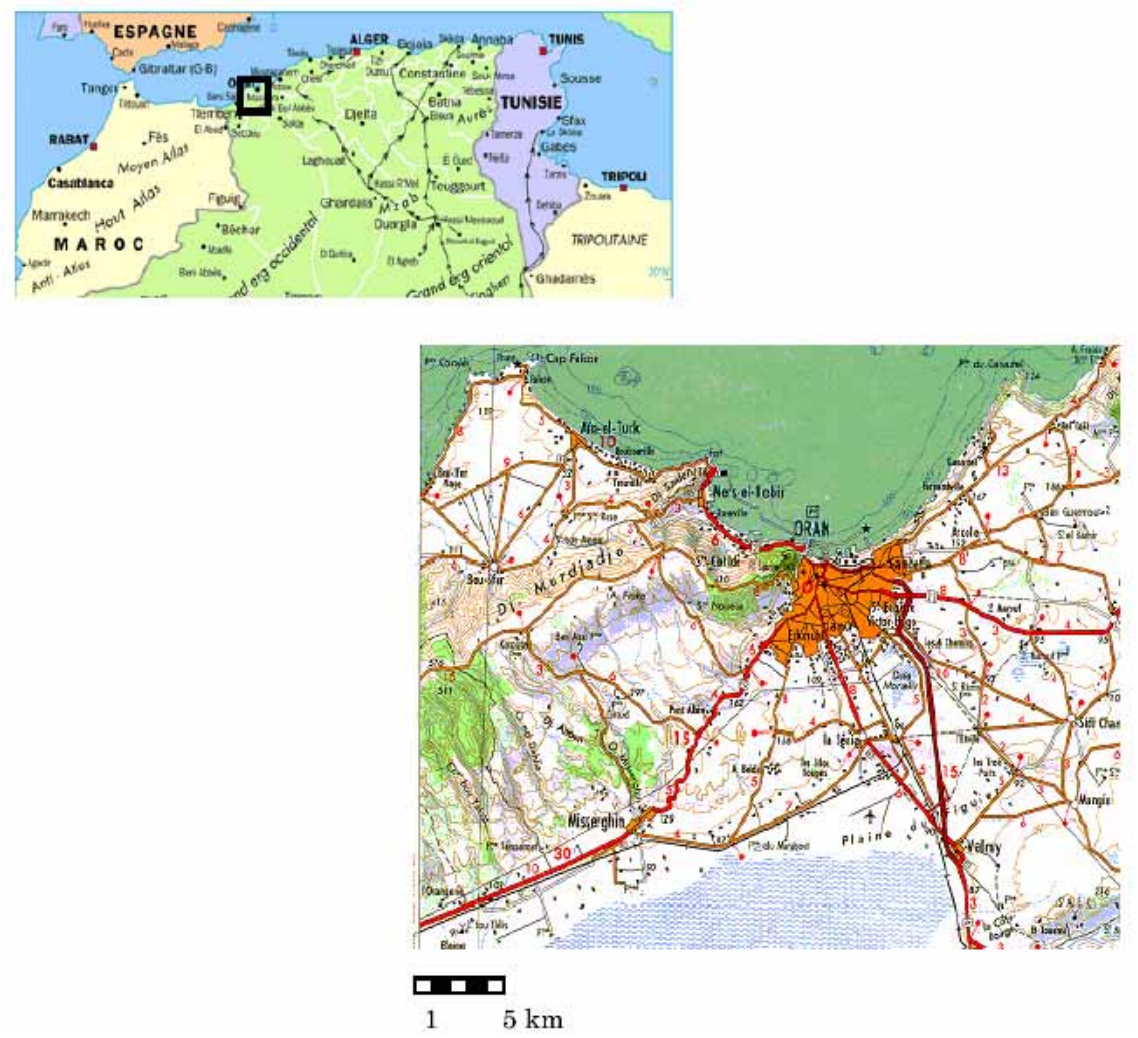


FIGURE 1 : Localisation de la zone d'étude (Oran-Ouest).*Location of the study area.*

Pour cela, on a choisi de réaliser une classification des données de HRV (XS) de SPOT réparties en 11 classes représentant les thèmes d'intérêt (eau, forêt dense, maquis, zones urbaines, sebkha, maraîchage, céréaliculture, jachère, sol nu, sable et zones de déferlement des vagues) d'occupation des terres de cette zone.

Les données représentées par la composition colorée (figure 2) des images satellitaires sont celles du capteur HRV de SPOT-4, acquises en mode multibande, prises le 1er avril 2001 à 10 h 46 et représentées dans une fenêtre de 1 024 x 1 024 pixels sur les bandes brutes XS1 (vert), XS2 (rouge) et XS3 (proche infrarouge).

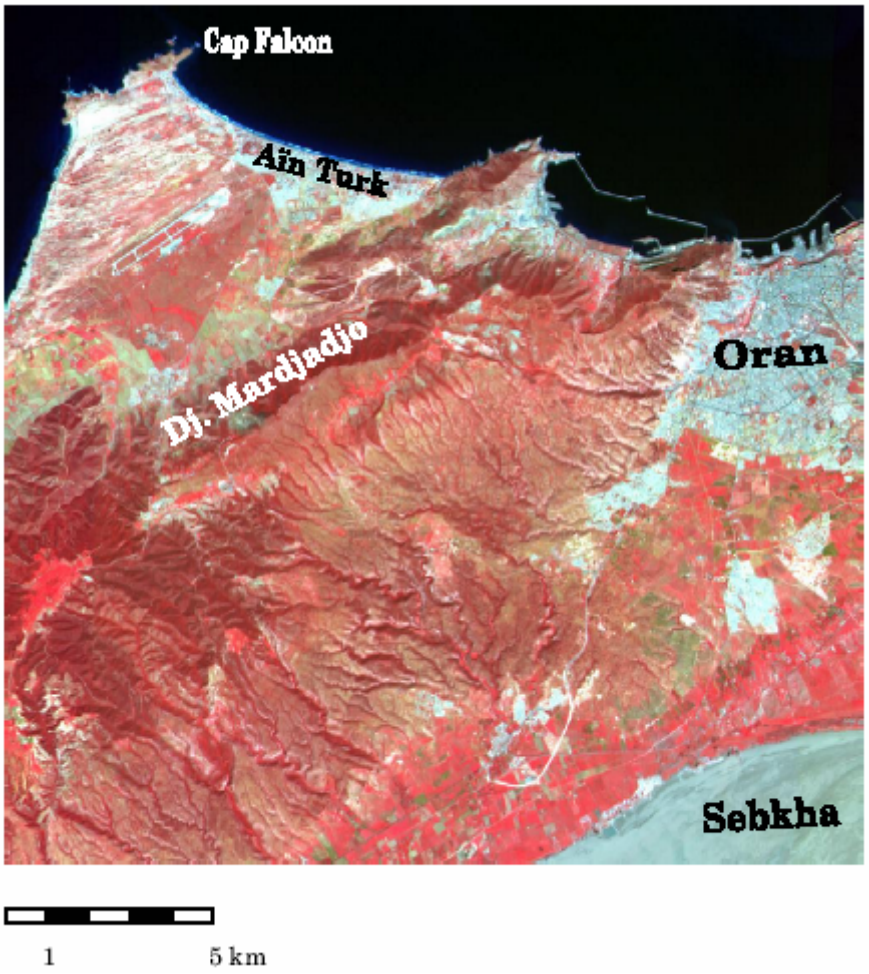


FIGURE 2 : Composition colorée des trois canaux de HRV de SPOT. *Color composite of the three SPOT HRV channels.*

3. ANALYSE DE TEXTURE

La texture est un élément important de la vision humaine. Une approche formelle ou une définition précise de la texture n'existe pas (Zahzah, 1992 ; Coroyer, 1996). Unser (1986) a proposé la définition suivante : « une texture est une région d'image pour laquelle il existe une fenêtre de dimension réduite, telle qu'une observation au travers de celle-ci se traduise par une impression visuelle identique pour toutes les positions envisageables par translation à l'intérieur de la région considérée » (Coroyer, 1996).

La texture s'évalue en général à l'aide de descripteurs. Un descripteur de texture est une information qui permet de quantifier la répétition spatiale d'un motif de base dans l'image. Certains de ces descripteurs correspondent à une propriété visuelle de la texture. D'autres correspondent à des propriétés purement mathématiques (Alata, 1998).

En d'autres termes, ce sont les invariants du type de stationnarité choisi qui sont, de manière intrinsèque, les descripteurs de la texture, justement parce qu'ils sont invariants dans l'hypothèse de stationnarité qui est faite.

Plusieurs méthodes d'extraction de descripteurs de texture ont été proposées par divers auteurs ; les quatre principales sont :

- les méthodes statistiques où les descripteurs sont fondés sur les calculs statistiques effectués sur les niveaux de gris des pixels de l'image ; c'est le cas des statistiques du

deuxième ordre comme les matrices de cooccurrence ou de longueurs de plages (Cocquerez et Philip, 1995 ; Coroyer, 1996 ; Tuceryan and Jain, 1998) ;
- les méthodes basées sur un modèle de texture où les descripteurs proviennent de l'identification des paramètres d'un modèle de texture (champs de Markov, modèle fractal, etc.) (Cocquerez et Philip, 1995 ; Coroyer, 1996 ; Tuceryan and Jain, 1998) ;
- les méthodes basées sur le filtrage où les descripteurs sont obtenus à la suite de transformations appliquées aux images (transformées de Fourrier, filtre de Gabor, ondelettes, etc.) ; les attributs texturaux seront calculés dans des domaines différents de celui de la grille spatiale des luminances (Cocquerez et Philip, 1995 ; Tuceryan and Jain, 1998) ;
- les méthodes géométriques où les descripteurs proviennent de l'application d'une méthode géométrique (diagrammes de Voronoï, géométrie différentielle, etc.) (Cocquerez et Philip, 1995 ; Tuceryan and Jain, 1998).

3.1. Méthode des matrices de cooccurrence

La méthode des matrices de cooccurrence demeure la méthode de référence pour l'analyse de la texture naturelle, car c'est la première qui présente un bon compromis entre la facilité de mise en œuvre et la performance. Cette méthode repose sur la stationnarité de l'image en loi conjointe, c'est-à-dire que la probabilité conjointe de niveaux i et j de pixels éloignés selon une translation T est un invariant qui caractérise donc la texture de l'image.

La méthode des matrices de cooccurrence exploite les relations qui existent entre les pixels de l'image dans une direction θ et une distance donnée d. Il s'agit en fait de la probabilité de trouver, si on part d'un pixel de valeur i, un pixel de valeur j quand on se déplace en suivant un vecteur dans la direction θ d'une distance d (Coroyer, 1996).

Les matrices de cooccurrence sont alors définies à partir d'une région R de l'image I et pour une translation T par :

$$P_T(i,j) = \frac{1}{N_c}\sum_R \delta(V_I(t),i)\cdot\delta(V_I(t+T),j) \qquad (1)$$

où $V_I(t)$ définit l'intensité du pixel (t) de l'image I ; $\delta(i,j)$ représente le symbole de Kronecker et N_C est le nombre de couple $(t, t+T)$ de la région (Coroyer, 1996).

Haralick et Shanmugam (1973) ont proposé quatorze paramètres descriptifs des textures à partir des matrices de cooccurrence. Si on définit Ng, le nombre de niveaux de gris de l'image sur laquelle on calcule les matrices de cooccurrence, il y a cinq paramètres qui sont plus fréquemment utilisés : le descripteur d'entropie (ENT), le moment angulaire du deuxième ordre (ASM) ou énergie, le descripteur de contraste (CON), le descripteur de corrélation (COR) et le descripteur d'homogénéité ou moment des différences inverses.

Le descripteur d'entropie s'exprime par :

$$ENT = \sum_i^{Ng}\sum_j^{Ng} P_T(i,j)\cdot\log(P_T(i,j)) \qquad (2)$$

L'entropie rend compte de la complexité de l'image en fournissant un indicateur sur le désordre que peut représenter sa texture.

Le moment angulaire du deuxième ordre s'exprime par :

$$ASM = \sum_i^{Ng}\sum_j^{Ng} P_T(i,j)^2 \qquad (3)$$

À l'inverse de l'entropie, ce moment mesure l'uniformité de la texture de l'image.

Le descripteur de contraste s'exprime par :

$$CON = \sum_i^{Ng} n^2 \sum_{|i-j|=n} P_T(i,j) \qquad (4)$$

Dans la mesure ou chaque terme de la matrice est pondéré par sa distance à la diagonale, le contraste est élevé quand les termes éloignés de la diagonale de la matrice sont élevés**.**

Le descripteur de corrélation s'exprime par :

$$COR = \frac{\sum_i^{Ng}\sum_j^{Ng}(i-j)\cdot P_T(i,j) - \mu_x\cdot\mu_y}{\sigma_x\cdot\sigma_y} \qquad (5)$$

avec $\mu_x,\mu_y,\sigma_x,\sigma_y$ qui sont les moyennes et les écarts types des marginales horizontales et verticales.
La corrélation est un indice qui mesure la dépendance linéaire des niveaux de gris dans l'image.
Le descripteur d'homogénéité s'exprime par :

$$HOM = \sum_i^{Ng}\sum_j^{Ng}\frac{1}{1+(i-j)^2}\cdot P_T(i,j) \qquad (6)$$

L'homogénéité est d'autant plus élevée que l'on retrouve souvent le même couple de pixels, ce qui est le cas lorsque le niveau de gris est uniforme ou quand il y a une périodicité spatiale.

Un important problème des matrices de cooccurrence est leur manipulation. En effet, elles sont de taille imposante et utilisent un grand espace de mémoire, puisque le nombre d'éléments qui les composent est de $Ng*Ng$ (Ng étant le nombre de niveaux de gris de l'image). C'est pour cette raison même que l'on calcule les descripteurs de Haralick et Shanmugam qui sont synthétiques. Ce sont en fait des moments et des entropies calculés sur la loi conjointe. Toutefois, en théorie, il est possible d'utiliser, comme descripteurs, directement les coefficients de la matrice de cooccurrence, qui est une estimation de la loi conjointe. Ce cas de figure

s'obtient lorsqu'on traite des textures binaires ou binarisées, la matrice de cooccurrence pour une direction étant de 2 x 2 et comprenant en fait seulement trois coefficients indépendants. Ce cas de figure se rencontre rarement en télédétection.

Il est donc nécessaire d'introduire une méthode qui va permettre de réduire l'utilisation de la mémoire et ainsi accélérer le traitement des images.

3.2. Algorithme SDH

L'algorithme SDH (*Sum and Difference Histograms* ou histogrammes de la somme et de la différence) offre une alternative aux traditionnelles matrice de cooccurrence. Des résultats expérimentaux ont montré que l'algorithme SDH était au moins aussi performant que la méthode des matrices de cooccurrence pour la discrimination de la texture (Unser, 1986). Autrement dit, avec cette méthode, la mémoire utilisée et le temps de calcul seront moindres (Alajarin Martinez-Cabeza-de-Vaca *et al*., 1999 ; Munzenmayer *et al*., 2002 ; Bugnet *et al*., 2003).

L'idée de base consiste à approcher la fonction de probabilité conjointe au moyen d'une combinaison de statistique du premier ordre de variables transformées et non corrélées (Alajarin Martinez-Cabeza-de-Vaca *et al*., 1999). Il est possible d'approcher la fonction de probabilité conjointe $P(i,j)$ au moyen de la fonction de probabilité conjointe $\widehat{P}(i,j)$ définie comme suit :

$$\widehat{P}(i,j) = c_0 * P_s(i+j) * P_d(i-j) \approx P(i,j) \qquad (7)$$

où c_0 est une constante qui est telle que :

$$\sum_i \widehat{P}(i,j) = 1 \cdot$$

Soit une image I représentée par une matrice de dimension $K*L$ dont les éléments sont $y_{k,l}$, $\{k = 0, \ldots, K-1 ; l=0, \ldots, L-1\}$. Appelons $G = \{0, 1, 2, \ldots, Ng-1\}$ l'ensemble des niveaux de gris. Introduisons la notion de somme et de différence de pixels :

$$\begin{cases} s_{k,l} = y_{k,l} + y_{k+d_1,l+d_2} \\ d_{k,l} = y_{k,l} - y_{k+d_1,l+d_2} \end{cases} \qquad (8)$$

Les valeurs possibles des couples *(d1, d2)* sont données sur la figure 3.

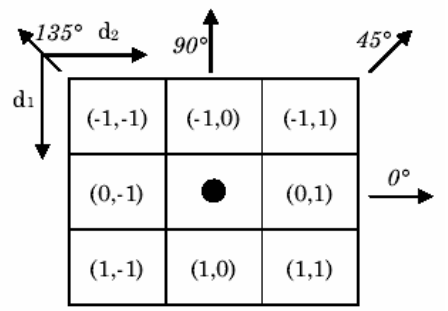


FIGURE 3 : Définition des distances des plus proches voisins du pixel. *Definition of the distances from the nearest neighbours of the pixel*

La définition des deux histogrammes de l'algorithme SDH des paramètres (d1, d2) se fait de manière fort similaire à la définition des matrices de cooccurrence. En effet, nous les obtenons en appliquant la définition suivante :

$$\begin{cases} h_s(i;d_1,d_2) = h_s(i) = card\{(k,l) \in I, s_{k,l} = i\} \\ h_d(i;d_1,d_2) = h_d(j) = card\{(k,l) \in I, d_{k,l} = j\} \end{cases} \qquad (9)$$

L'algorithme SDH utilise deux vecteurs normalisés de dimension *[2Ng-1]* formés des éléments $\widehat{P}_s(i)$ et $\widehat{P}_d(j)$ définis comme suit :

$$\begin{cases} \widehat{P}_s(i) = \dfrac{h_s(i)}{N} \qquad (i = 1,\ldots,2N_g - 1) \\ \widehat{P}_d(j) = \dfrac{h_d(i)}{N} \qquad (j = -N_g + 1,\ldots,N_g - 1) \\ N = \sum_i h_s(i) = \sum_j h_d(j) \end{cases} \qquad (10)$$

où $\widehat{P}_s(i)$ et $\widehat{P}_d(j)$ sont les estimateurs des fonctions de probabilité de la somme et de la différence définies par :

$$\begin{cases} P_s(i) = \text{Proba}\{s_{k,l} = i\} \qquad (i = 1,\ldots,2N_g - 1) \\ P_d(j) = \text{Proba}\{d_{k,l} = j\} \qquad (j = -N_g + 1,\ldots,N_g - 1) \end{cases} \qquad (11)$$

Tout comme pour les matrices de cooccurrence, nous allons utiliser certains descripteurs et les adapter directement à partir des vecteurs $\widehat{P}_s(i)$ et $\widehat{P}_d(j)$. Sur le tableau 1, on peut voir un rappel de ces descripteurs et de leur équivalent pour une utilisation dans l'algorithme SDH. En observant les descripteurs des matrices de cooccurrence et de leurs équivalents pour l'algorithme SDH, nous remarquons que ces derniers donnent exactement les mêmes valeurs pour cinq des sept descripteurs. La valeur de l'approximation de l'entropie et de l'énergie est très proche de la valeur trouvée avec les matrices de cooccurrence.

TABLEAU 1 : Descripteurs de la matrice de cooccurrence et leurs équivalents pour l'algorithme SDH. *Cooccurrence matrix descriptors and their equivalents for the SDH algorithm*

Descripteur	Matrice de cooccurrence	SDH
Moyenne	$\sum_i \sum_j ip(i,j)$	$= \frac{1}{2} \sum i \hat{P}_s(i) = \mu$
Variance	$\sum_i \sum_j (i-\mu)^2 p(i,j)$	$= \frac{1}{2}\left[\sum_i (i-2\mu)^2 \hat{P}_s(i) + \sum_j j^2 \hat{P}_d(j) \right]$
Énergie	$\sum_i \sum_j \{p(i,j)\}^2$	$\approx \sum_i \hat{P}_s(i) * \sum_j \hat{P}_d(j)^2$
Corrélation	$\sum_i \sum_j (i-\mu)(j-\mu) p(i,j)$	$= \frac{1}{2}\left[\sum_i (i-2\mu)^2 \hat{P}_s(i) - \sum_j j^2 \hat{P}_d(j) \right]$
Entropie	$\sum_i \sum_j - p(i,j) \log_2 \{p(i,j)\}$	$\approx \sqrt{\sum_i \hat{P}_s(i) \log_2 (\hat{P}_s(i)) - \sum_j \hat{P}_d(j)}$
Contraste	$\sum_i \sum_j (i-j)^2 p(i,j)$	$= \sum_j j^2 \hat{P}_d(j)$
Homogénéité	$\sum_i \sum_j \frac{1}{1+(i-j)^2} p(i,j)$	$= \sum_j \frac{1}{1+j^2} \hat{P}_d(j)$

SDH (histogrammes de la somme et de la différence ; tiré de (Bugnet *et al*., 2003)

4. CLASSIFICATION

Afin d'évaluer la performance des différents paramètres spectraux ou texturaux, nous avons utilisé un classificateur neuronal dirigé de type perceptron multicouche. Ce type de classificateur permet de manipuler des données regroupées dans un vecteur, sans tenir compte ni de leur distribution ni de leur unité. À partir de ces données, il construit sa présentation interne qui fera correspondre le vecteur d'entrée à un autre vecteur de sortie (Zahzah, 1992).

Un réseau neuronal simple est constitué de trois couches d'unités : la couche d'entrée, la couche cachée et la couche de sortie. Les unités de chaque couche sont reliées aux unités de la couche suivante. Les sorties du réseau sont représentées par un vecteur à n dimensions, n étant le nombre de classes. Lors de l'apprentissage de la classe C_i par le réseau, toutes les composantes du vecteur de sortie seront mises à zéro sauf la i^e composante, qui sera mise à 1.

Un problème crucial pour réaliser un réseau de neurones multicouche est la détermination du nombre de neurones dans les couches cachées. S'il y a trop peu de neurones, le réseau ne peut pas s'adapter à tous les exemples d'apprentissage. Autrement dit, si le réseau possède un grand nombre de neurones cachés, il risque de s'ajuster au bruit qui est présent dans les données de la base d'apprentissage et donc de posséder de mauvaises propriétés de généralisation (Hosseini *et al*., 2002). Le problème de la détermination de l'architecture optimale est pendant longtemps demeuré un problème ouvert.

Dans notre test, on a essayé plusieurs configurations du réseau de neurones. Le meilleur résultat de classification dans la phase de test est celui qui a été obtenu avec un réseau de 15 neurones cachés. Dans notre application, plusieurs tests ont été effectués afin de déterminer une architecture optimale du classificateur neuronal permettant une meilleure généralisation.

5. APPLICATION

Dans le cadre de cet article, un double objectif a été fixé : 1) montrer l'apport d'intégration de données texturales pour améliorer la classification basée uniquement sur les données radiométriques et 2) évaluer la méthode de l'algorithme SDH par rapport à la méthode classique des matrices de cooccurrence. En fonction de ces deux objectifs, trois tests ont été envisagés :

- le premier test consiste en une classification purement spectrale ;
- le second test est une classification combinée intégrant l'information spectrale contenue

dans les trois canaux XS et les sept paramètres de texture provenant de la méthode d'analyse texturale de Haralick et Shanmugam (algorithme de cooccurrence) ;
- le troisième test est identique au second, sauf que l'algorithme de cooccurrence est remplacé par celui de la méthode de l'algorithme SDH.

Dans notre application, plusieurs tests ont été effectués afin de déterminer une architecture optimale du classificateur neuronal, permettant une meilleure généralisation. Le tableau 2 montre les valeurs testées représentées sur le graphe de la figure 5. Nous avons finalement retenu la valeur de 15 neurones cachés qui donne la meilleure précision de classification sur les données de validation (classification texturale).

TABLEAU 2 : Nombre de neurones dans la couche cachée testée. *Number of neurons in the hidden layer tested.*

Nombre de neurones cachés	Précision de l'apprentissage) (%)	Précision de la validation) (%)
5	88,3	85,0
10	92,3	91,0
15	94,3	92,9
20	92,7	91,8

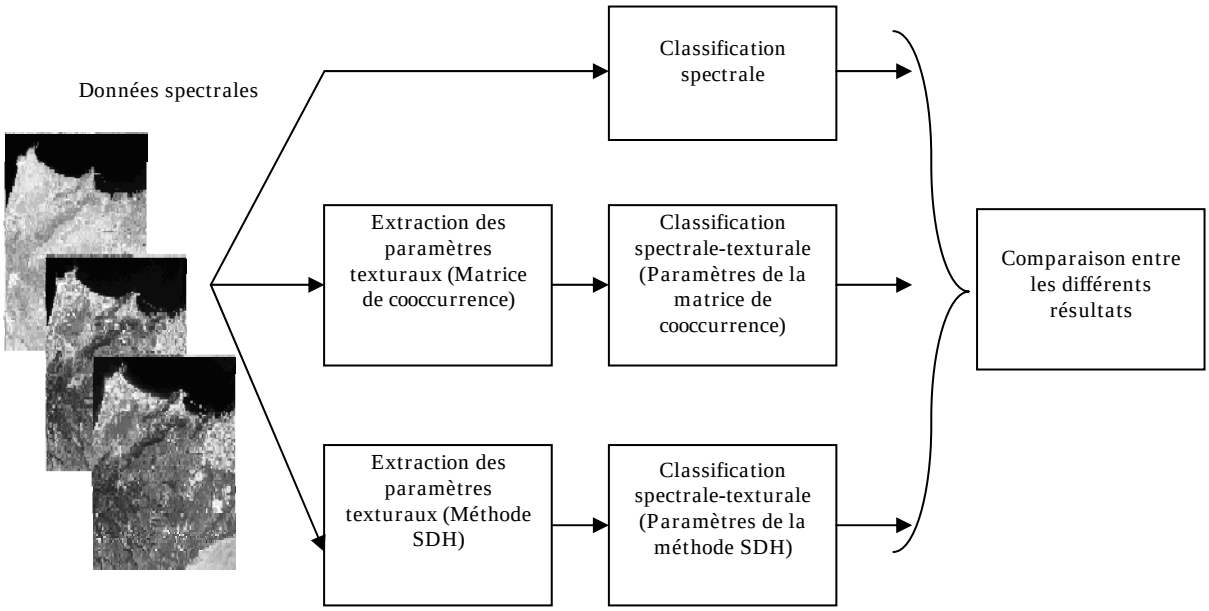


FIGURE 4 : Différents tests effectués. *Different tests made.*

5.1. Tests réalisés

Pour les classifications effectuées, nous avons d'abord utilisé les canaux bruts du radiomètre (cas spectral) et ensuite ajouté les images de texture dans les autres cas (approche texturale). Un ensemble d'échantillons représentant les thèmes d'intérêt (eau, forêt dense, maquis, zones urbaines, sebkha, maraîchage, céréaliculture, jachère, sol nu, sable et zones de déferlement des vagues) a été choisi sur l'image afin de servir dans la phase d'apprentissage et de calcul de la matrice de confusion.

Sur la figure 4, on présente l'organigramme méthodologique général utilisé pour les différentes classifications réalisées.

La génération de différents paramètres texturaux, les opérations de classification et la mise en forme de la carte d'occupation des terres ont été effectuées à l'aide d'un logiciel écrit avec le langage c++ (Borland Builder c++). Tous les traitements inhérents à ce travail ont été réalisés sur un PC Pentium III.

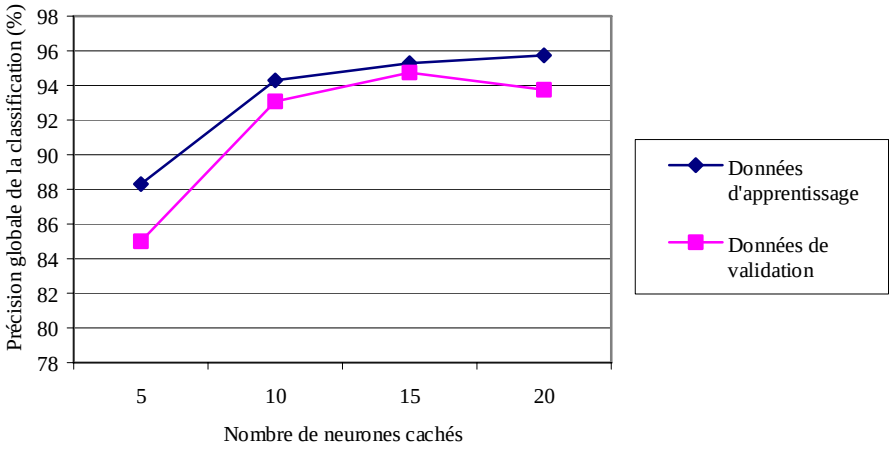


FIGURE 5 : Précision globale de la classification en fonction de neurones cachés *Global classification accuracy as a function of hidden neurons.*

6. RÉSULTATS EXPÉRIMENTAUX ET DISCUSSION

6.1. Première expérimentation : classification spectrale

Pour ce test, on a choisi de réaliser une classification spectrale des données de HRV (XS) répartie en 11 classes thématiques : eau, forêt dense, maquis, zones urbaines, sebkha maraîchage, céréaliculture, jachère, sol nu, sable et zones de déferlement des vagues. Les résultats de la classification des trois bandes XS sont représentés sur la figure 6.

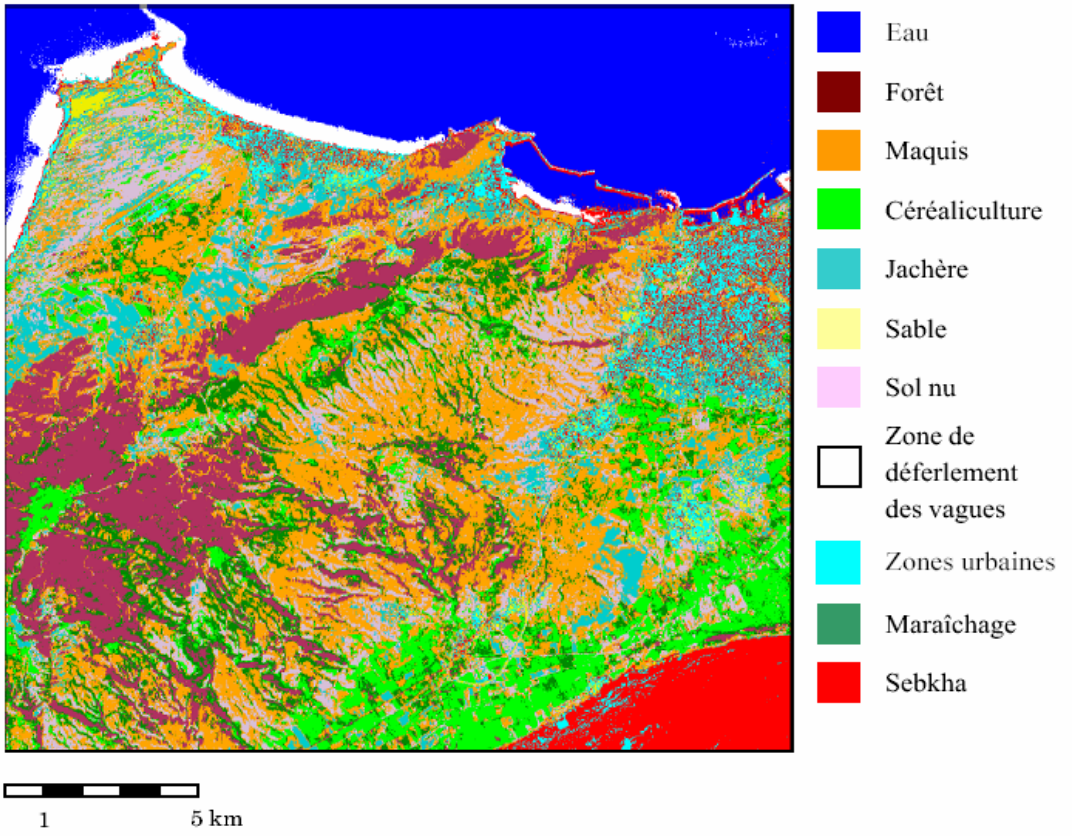


FIGURE 6 : Classification dirigée des trois canaux de HRV de SPOT. *Supervised classification of three SPOT HRV channels.*

La matrice de confusion (tableau 3) montre l'existence de confusion entre certaines classes. Celles qui sont particulièrement moins bien classées sont :

- la classe maraîchage avec seulement 47,5 % de pixels bien classés ;
- la classe zones urbaines avec 69,3 % de pixels bien classés.

Pour la classe maraîchage, cette confusion existe principalement entre les classes forêt, maquis et céréaliculture. Quant aux zones urbaines, la confusion concerne surtout la classe sebkha et, à un degré moindre, les classes sable et jachère. Toutes ces confusions sont dues à la proximité des réponses spectrales des thèmes concernés dans l'image de HRV (XS). L'intégration d'une autre donnée (information texturale) s'avère donc nécessaire afin de lever cette confusion.

Pour les autres classes d'occupation des terres, le taux de confusion est très faible.

La précision globale de la classification spectrale des pixels ayant servi à la validation est de 88,4 %, avec un cœfficient Kappa avoisinant 87 %, c'est-à-dire que 87 % des erreurs de la classification sont évitées.

TABLEAU 3 : Matrice de confusion de la classification des canaux de HRV de SPOT. *Confusion matrix of the classification of the SPOT HRV channels.*

	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**
1 - Zones urbaines	693	0	0	0	0	0	0	29	15	0	0
2 - Sol nu	0	895	0	49	5	1	34	23	0	0	0
3 - Forêt	0	0	993	6	0	4	149	0	0	0	0
4 – Maquis	2	81	1	900	39	0	147	27	0	0	0
5 – Jachères	33	15	0	1	956	0	13	67	0	0	0
6 – Céréalicultures	0	5	0	5	0	989	179	0	0	0	0
7 – Maraîchage	0	0	6	39	0	6	475	0	0	0	0
8 – Sable	46	4	0	0	0	0	3	843	0	0	0
9 – Sebkha	226	0	0	0	0	0	0	11	985	0	0
10 - Zone de déferlement des vagues	0	0	0	0	0	0	0	0	0	1000	0
11 – Eau	0	0	0	0	0	0	0	0	0	0	1000
Taux de bonne classification (%)	69,3	89,5	99,3	90,0	95,6	98,9	47,5	84,3	98,5	100	100
Taux global de bonne classification 88,4 %											
Coefficient Kappa 87,3 %											

6.2. Deuxième expérimentation : classification utilisant la matrice de cooccurrence

Pour la première classification combinée de l'image de HRV (XS), on procède à une analyse texturale de l'image de la bande verte (qui, par appréciation visuelle, semble la plus riche en information de texture) par la méthode de Haralick et Shanmugam pour l'extraction de sept paramètres de texture.

La question principale lors de la génération des paramètres texturaux concerne le choix de la taille de la fenêtre d'analyse. Habituellement, une fenêtre de petite taille réduit le risque d'avoir plusieurs classes dans la même fenêtre, mais les paramètres calculés dans ce cas sont très fragiles. Autrement dit, une fenêtre de grande taille améliore la classification car un nombre important de pixels permet de calculer des statistiques fiables mais, en même temps, il y a un risque d'obtenir des pixels de classes différentes contenus dans la même fenêtre. De plus, l'utilisation des grandes fenêtres implique l'effet de bordure qui pose un grand problème aux classificateurs (Djerriri, 2004).

Sur le tableau 4, on montre les valeurs de fenêtres mobiles testées dans cette expérimentation et représentées sur la figure 7. La fenêtre de 5 x 5 pixels a été retenue et ce choix est justifié, d'une part, par la qualité visuelle des images des paramètres de texture et, d'autre part, par la précision globale élevée de la classification utilisant ces paramètres.

TABLEAU 4 : Tailles de fenêtres testées. *Tested windows sizes.*

Dimension de la fenêtre	Précision de l'apprentissage) (%)	Précision de la validation) (%)
3 x 3	91,4	90,0
5 x 5	94,3	92,9
7 x 7	93,6	91,9
9 x 9	91,0	90,9

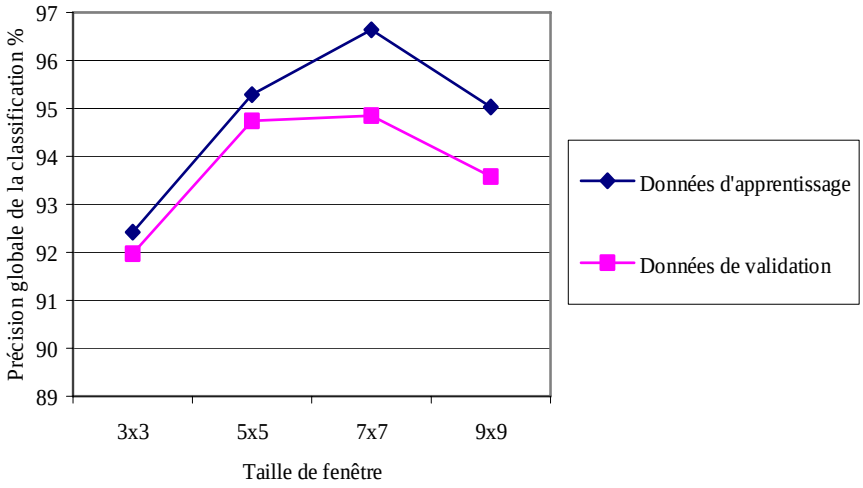


FIGURE 7 : Précision globale de classification en fonction de la taille de la fenêtre d'analyse. *Global classification accuracy as a function of window size.*

Les résultats obtenus par cette première classification combinée sont présentés sur la figure 8.

L'examen des résultats provenant de la matrice de confusion (tableau 5) montre que la confusion relevée précédemment a été considérablement diminuée. Une amélioration du taux de bonne classification de 35,5 % et de 26,7 % a été obtenue, respectivement, pour le maraîchage et les zones urbaines. La confusion entre les zones urbaines et la sebkha a été presque éliminée tandis que la confusion entre les autres thèmes est considérablement diminuée.

La précision globale de la classification des pixels ayant servi à la validation est améliorée. Elle est de 92,9 % avec un indice de Kappa avoisinant 92,2 %.

L'intégration des paramètres de texture (moyenne, variance, contraste, homogénéité, corrélation, entropie et énergie) apporte une amélioration considérable à la classification. Grâce à ces mesures, une amélioration de 4,5 % est enregistrée par rapport à la méthode utilisant uniquement les données spectrales.

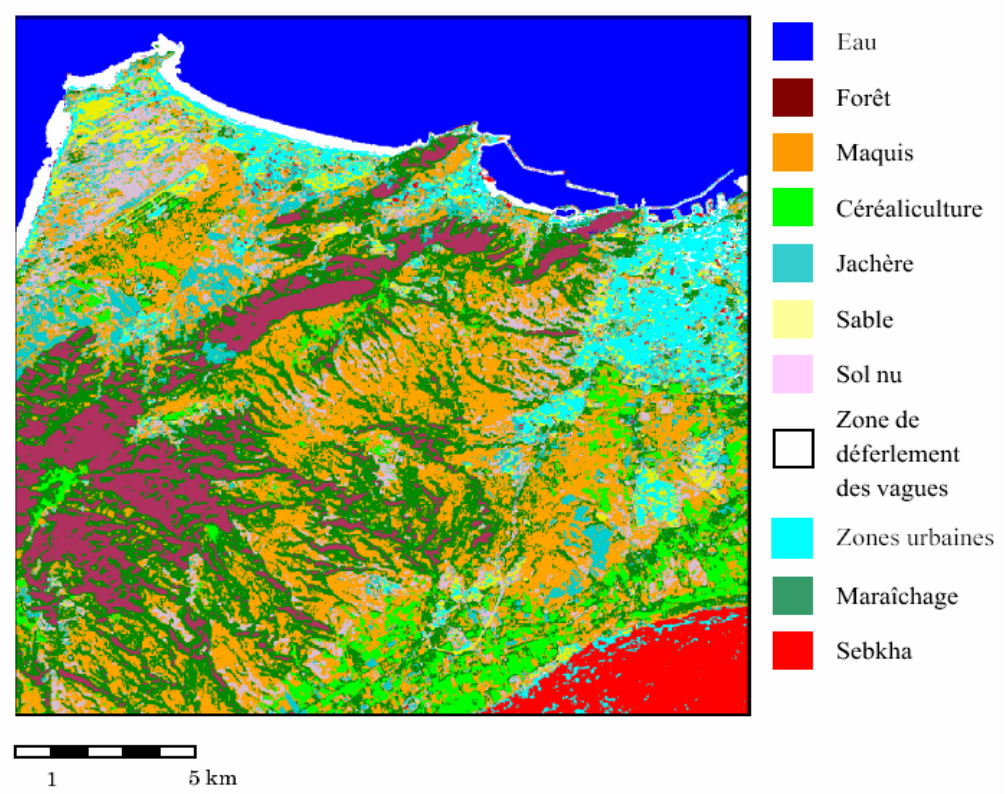


FIGURE 8 : Classification utilisant les indices de la matrice de cooccurrence.
Cooccurrence matrix based classification

TABLEAU 5 : Matrice de confusion de la matrice de cooccurrence. *Confusion matrix of the cooccurrence matrix.*

	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**
1 - Zones urbaines	960	0	0	0	0	0	0	54	23	0	0
2 - Sol nu	0	753	0	21	3	0	13	7	0	0	0
3 - Forêt	0	0	957	0	0	0	17	0	0	0	0
4 - Maquis	0	213	0	912	36	7	85	0	0	0	0
5 - Jachères	0	31	0	3	949	0	6	0	0	0	0
6 – Céréalicultures	0	1	0	0	0	940	48	0	0	0	0
7 – Maraîchage	0	2	43	64	8	53	831	0	0	0	0
8 – Sable	19	0	0	0	0	0	0	938	0	0	0
9 – Sebkha	21	0	0	0	4	0	0	1	977	0	0
10 - Zone de déferlement des vagues	0	0	0	0	0	0	0	0	0	1000	0
11 - Eau	0	0	0	0	0		0	0	0	0	1000
Taux de bonne classification (%)	96,0	75,3	95,7	91,2	94,9	94,0	83,1	93,8	97,7	100	100
Taux global de bonne classification 92,9 %											
Coefficient Kappa 92,2 %											

6.3. Troisième expérimentation : classification provenant de l'algorithme SDH

Pour la deuxième classification combinée de l'image de HRV (XS), on procède à une analyse texturale de l'image de la bande verte par la méthode d'Unser (algorithme SDH) pour l'extraction des sept paramètres de texture. Les résultats obtenus par cette deuxième classification combinée sont présentés sur la figure 9.

L'examen des statistiques provenant de la matrice de confusion (tableau 6) montre que le taux de bonne classification (94,6 %) est globalement meilleur que celui qui a été obtenu dans le cas de la matrice de cooccurrence (92,9 %).

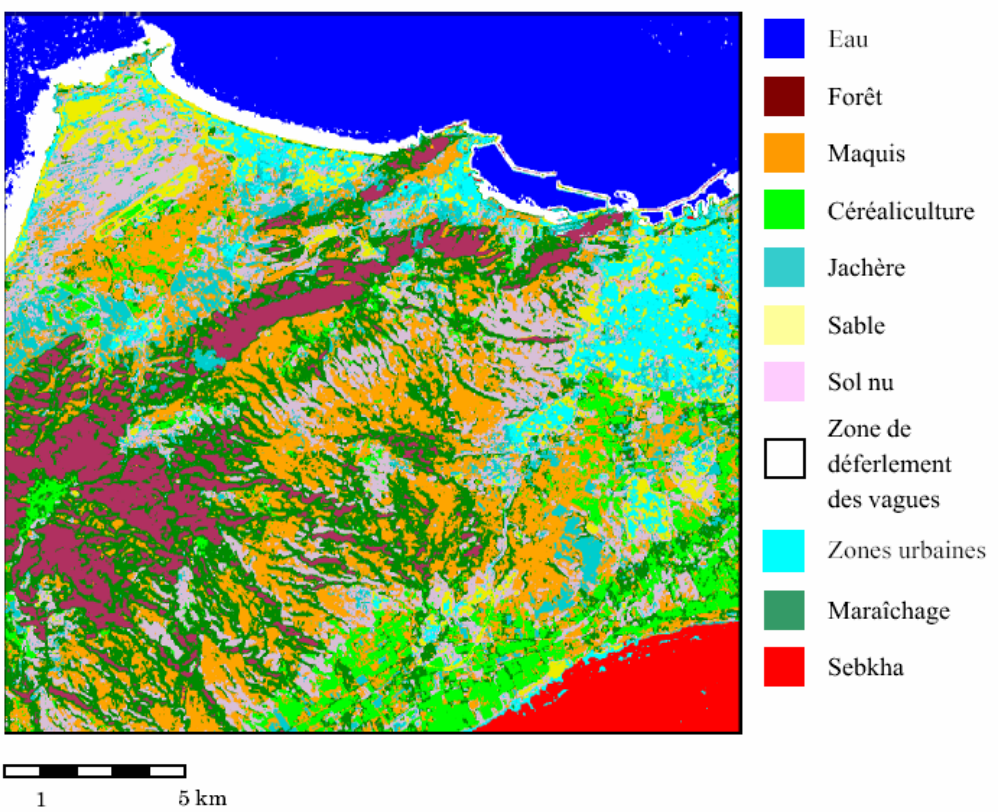


FIGURE 9 : Classification utilisant les indices de texture provenant de l'algorithme SDH.
SDH method index based classification

TABLEAU 6 : Matrice de confusion de l'algorithme SDH. *Confusion matrix of the SDH algorithm.*

	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**
1 - Zones urbaines	970	0	0	0	0	0	1	4	0	0	0
2 - Sol nu	0	868	0	30	4	0	60	10	0	0	0
3 - Forêt	0	0	954	0	0	0	10	0	0	0	0
4 – Maquis	0	121	0	932	28	3	54	0	0	0	0
5 – Jachères	1	10	0	1	961	0	10	1	0	0	0
6 – Céréalicultures	0	1	0	4	0	961	74	0	0	0	0
7 – Maraîchage	0	0	46	33	7	36	781	0	0	0	0
8 – Sable	28	0	0	0	0	0	10	985	0	0	0
9 - Sebkha	1	0	0	0	0	0	0	0	1000	0	0
10 - Zone de déferlement des vagues	0	0	0	0	0	0	0	0	0	1000	0
11 - Eau	0	0	0	0	0	0	0	0	0	0	1000
Taux de bonne classification (%)	97,0	86,8	95,4	93,2	96,1	96,1	78,1	98,5	100	100	100
Taux global de bonne classification 94,6 %											
Coefficient Kappa 94,1 %											

La précision globale de la classification des pixels ayant servi à la validation est de 94,6 %, avec un indice de Kappa avoisinant 94 %. La confusion entre les zones urbaines et la sebkha est pratiquement disparue. En revanche, on constate une légère baisse du taux de bonne classification du thème maraîchage par rapport à la méthode des matrices de cooccurrence. Ceci est essentiellement dû à la confusion avec le thème sol nu.

Le taux de bonne classification global et par thème obtenu pour les trois approches utilisées est représenté sur le tableau 7, qui contient en plus le temps de calcul et l'espace de mémoire utilisés pour le calcul des paramètres texturaux. Ces résultats montrent clairement les avantages de la méthode de l'algorithme SDH avec un temps de calcul divisé par environ 5 et un espace de mémoire utilisé réduit de

quatre fois par rapport à celui de la méthode des matrices de cooccurrence.

TABLEAU 7 : Tableau comparatif des trois approches utilisées. *Comparative table of the three approaches used.*

SDH = histogramme de la somme et de la différence

Classes	Taux de bonne classification (%)		
	Spectral	Cooccurrence	SDH
Zones urbaines	69,3	96,0	97,0
Sol nu	89,6	75,3	86,8
Forêt	99,7	95,7	95,4
Maquis	90,3	91,2	93,2
Jachères	95,7	95,0	96,2
Céréaliculture	98,9	94,0	96,1
Maraîchage	47,5	83,1	78,1
Sable	85,0	93,8	98,5
Sebkha	98,5	97,7	100
Zone de déferlement des vagues	100	100	100
Eau	100	100	100
Total	88,4	92,9	94,6
Temps de calcul (s)	/	231	49
Espace de mémoire (ko)	/	262 144	65 536

7. CONCLUSION

Dans l'optique de démonter l'apport de l'intégration des données texturales dans un processus classificatoire des images multibandes de la région d'Oran, nous avons réalisé trois classifications. Dans le premier cas, nous avons procédé à une classification spectrale des trois canaux (XS1, XS2 et XS3) en utilisant un classificateur neuronal de type perceptron multicouche. Le taux de bonne classification acquis a été de 88,4 %, avec un coefficient de Kappa de 87 %.

Dans le deuxième cas, nous avons généré un ensemble de sept paramètres de texture à l'aide de la méthode de Haralick et Shanmugam. Cette classification a donné de meilleurs résultats que la précédente avec un taux de bonne classification de 92,9 % et un Kappa de 92,2 %. Toutefois, cette méthode présente l'inconvénient lié à la taille imposante des matrices de cooccurrence utilisant un grand espace de mémoire, notamment dans le cas de la non réduction des niveaux de gris de l'image de travail.

La classification obtenue à partir de l'ensemble des paramètres provenant de l'algorithme SDH donne un taux de bonne classification de 94,6 %, avec un coefficient Kappa de 94,1 %.

Ces résultats montrent une nette amélioration de la classification avec l'intégration des paramètres texturaux et que cette amélioration est plus importante dans le cas de la méthode SDH qui présente, en plus, de bonnes performances en matière de mémoire informatique utilisée et de temps de calcul.

Références

Alajarin Martinez-Cabeza-de-Vaca, J., Tomas-Balibrea, L.-M., Solina, F. and Leonardis, A. (1999) Automatic classification system of marble slabs in production line according to texture and color using artificial neural networks. P. 167-174, in Springer-Verlag (réd.) Computer Analysis of Images and Patterns : Proceedings of the 8th International Conference, CAIP '99, Ljubljana, September 1999, Berlin.

Alata, O. (1998) Caractérisation de texture par coefficient de réflexion 2D : application en classification et segmentation. Thèse de doctorat, Université de Bordeaux I, 161 p.

Bugnet, P., Cavayas, F. et Gagnon, L. (2003) Vers la cartographie automatisée des surfaces boisées en milieu urbanisé fondée sur la texture d'images IKONOS panchromatiques. Journal canadien de télédétection, vol. 29, p. 755-769.

Cocquerez, J.-P. et Philip, S. (1995) Analyse d'images : Filtrage et segmentation. Masson, Paris, 488 p.

Coroyer, C. (1996) Apports des corrélations d'ordre élevé à l'analyse de textures non gaussiennes. Thèse de doctorat, Université Cergy-Pontoise, France, 121 p.

Djerriri, K. (2004) Approche neuro-génétique pour la classification des images de télédétection intégrant l'information de texture. Mémoire de magistère, Centre national des techniques spatiales, Arzew, 110 p.

Haralick, R.M. and Shanmugam, K. (1973) Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics, vol. 3, n° 6, p. 610-621.

Hosseini, E. A, Amini, J. and Saradjian M.R. (2002) Back propagation neural network for classification of IRS-1D satellite images. Department of Geomatics, Faculty of Engineering, Tehran University, Iran, 5 p.

Munzenmayer, C., Volk, H., Kublbeck, C., Spinnler, K. and Wittenberg, T. (2002)
Multispectral texture analysis using interplane sum-and difference-histograms. P. 42-49,
in Springer Berlin (réd.) Pattern Recognition : Proceedings of the 24th DAGM Symposium, Zurich, September 16-18, 2002, Heidelberg.

Puissant, A. (2003) Information géographique et images à très haute résolution : Utilité et application en milieu urbain. Thèse de doctorat, Université Louis Pasteur, Strasbourg, 445 p.

Tuceryan, M. and Jain, A.K. (1998) Texture analysis. P. 207-248, in C. H. Chen, L. F. Pau, and P. S. P. Wang (réd.) Handbook of Pattern Recognition and Computer Vision, World Scientific Publishing Company, Hackensack, NJ, 1044 p.

Unser, M. (1986) Sum and difference histograms for texture classification. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 8, n° 1, p. 118-125.

Zahzah, E. (1992) Contribution à la présentation des connaissances et leur utilisation pour l'interprétation automatique des images satellite. Thèse de doctorat, Université Paul Sabatier, Toulouse, 286 p.