*Télédétection*, 2003, vol. 3, n° 2-3-4, p. 361–372
Droit de photocopie soumis à l'autorisation

© 2003 CONTEMPORARY PUBLISHING INTERNATIONAL
Publié sous l'enseigne *Éditions scientifiques GB*
Imprimé en France

# APPROCHE DE CLASSIFICATION PAR RÉSEAUX DE KOHONEN POUR ÉTABLIR DES CARTES D'OCCUPATION DU SOL DE LA RÉGION D'ORAN (ALGÉRIE)

TAHAR IFTENE[*a], HABIB MAHI[†a] et HADRIA ISABATEN[b].

[a] *Centre National des Techniques Spatiales*
*B.P. 13, Arsew 3120, Oran, Algérie.*
*Téléphone : (213) 41 47 25 79 ; télécopieur : (213) 41 47 34 54*

[b] *Institut d'Informatique, Université des Sciences et de la Technologie d'Oran*
*3120, Oran, Algérie.*
*Courriel [(*, †)] : iftenet@cnts.dz ; mahi@cnts.dz*

*(soumis le 25 février 2002 ; révisé le 6 mai 2002 ; accepté le 11 décembre 2002)*

Dans le processus d'élaboration des cartes d'occupation du sol à partir des images satellitaires, on constate souvent l'insuffisance des résultats obtenus par les méthodes de classification classiques basées sur des critères de ressemblance spectraux ou texturaux. Ces méthodes présentent une limite certaine lorsqu'il s'agit de situations complexes : topographie accidentée, confusion de thèmes et ombrage. De plus, la perspective d'utilisation de données exogènes se heurte à la difficulté d'intégration de celles obéissant à des lois de distribution différentes. Afin de pallier ces lacunes, une approche basée sur les réseaux de neurones et utilisant les cartes topologiques de Kohonen a été élaborée. Ces cartes présentent une nouvelle stratégie de classification utilisant un principe de compétition et de coopération pouvant remédier aux aléas liés aux classifications classiques. Le travail réalisé consiste à utiliser les cartes topologiques de Kohonen pour réaliser une classification sur des images TM de Landsat de la région d'Oran, prise comme zone test, pour la variété des thèmes en présence (eau, forêt, céréaliculture, zones urbaines, etc.) et son relief relativement accidenté.

L'apprentissage du réseau est conçu à partir d'un échantillonnage aléatoire ou systématique aléatoire. Après la phase de généralisation, la calibration sert à préciser, pour chaque thème de l'image de classes, un intervalle de radiométrie dans les bandes spectrales utilisées, pour un étiquetage des neurones de la couche de sortie.

Enfin, l'intégration d'une donnée dérivée du modèle numérique d'altitude, la pente, sert à lever certaines confusions parmi celles observées lors de la classification basée uniquement sur les données spectrales, notamment entre les zones d'ombre et l'eau, ainsi qu'entre les zones urbaines et la sebkha. L'image classifiée ainsi obtenue sert à élaborer la carte d'occupation du sol de la région d'Oran-Ouest.

*Mots-clefs : Classification ; images satellitaires ; réseau de neurones ; carte organisatrice de Kohonen ; données exogènes.*

# THE KOHONEN'S NETWORK CLASSIFICATION APPROACH USED FOR LAND COVER MAPPING : CASE OF ORAN AREA (ALGERIA)

It is often noticed when mapping the land cover from satellite images, that there is a lack of results obtained by classical methods of classification. In general, the last ones provide a data analysis by grouping the pixels into classes, according to the similarity and resemblance criterions spectral or textural presenting a certain limit, especially in complex situations ; particularly in the case of a variable topography of the region of study. In addition, the prospects use of an exogenic data is faced by the difficulty of the noisy data integration obeying to different distribution laws. In order to mitigate these gaps, an approach based on the neural networks and using the Kohonen's topological maps is set. The Kohonen's topological maps provide a new strategy of classification using a competition and co-operation principal being able to cure the risks related to the classical classification.

First, the task consists of implementing this algorithm to set up a classification on Landsat TM images in the region of Oran related as a test zone due to its various themes (sea, forest, urban, etc.), its relatively variable relief. The network will be designed from a random sampling or a random systematic. Once the generalization step is achieved, the calibration will serve again to precise, for each topic of the image classes, a radiometric interval in the different spectral bands. This allows a "libelisation" of the neurons of the output layer. Finally, the integration of the derived data of the DTM (Digital Terrain Model), in fact the slope, will serve to raise the confusion among those observed when the classification was based only on the radiometric data, in particular between shadow and sea and between the urban zones and the sebkha. Whenever the classified image is made, it will be used to make the land cover map of the west area of Oran.

*Keywords : Classification ; Satellite Images ; Neural Networks ; Exogenic Data ; Kohonen's organizing map.*

---

[*] Correspondant principal

## 1. INTRODUCTION

Conçu par Mc Culloch et Pitts en 1943, le modèle du neurone formel dérivé du modèle biologique a connu un essor important vers les années 1980. Cette émergence est étroitement liée, d'une part, à sa capacité de traitement des données incomplètes, incertaines ou bruitées et, d'autre part, à son application dans divers domaines allant de l'aide à la décision, à la planification et jusqu'aux domaines de la reconnaissance de formes et de la classification (Jodouin, 1994).

Pour le domaine de la classification d'images satellitaires, les méthodes de classification classiques permettent, en général, une analyse de données en les regroupant en classes en fonction de critères de ressemblance ou de similarité entre individus formant l'ensemble à classifier. Ces méthodes sont mal adaptées lorsqu'il s'agit de traiter des données obéissant à des lois de distribution différentes (Zahzah, 1992). Ces méthodes de classification en mode dirigé ou non dirigé ont démontré leur impuissance lorsqu'il s'agit de situations complexes notamment dans les cas :

– d'une topographie accidentée de la région à étudier ;

– d'hétérogénéité des systèmes de mesure lors d'intégration de données issues de différentes sources.

Les cartes topologiques de Kohonen présentent une nouvelle stratégie de classification en se basant sur un mode non dirigé et un principe de compétition et de coopération. Leur capacité de découvrir automatiquement des catégories dans un ensemble de données fait de ces réseaux des techniques efficaces de classification (Lambert, 1999).

L'objectif de cet article est d'abord d'utiliser ces cartes pour ensuite les tester à travers une classification sur des images, du capteur Thematic Mapper (TM) du satellite Landsat, dans la région d'Oran.

L'intérêt de cette approche par réseaux de Kohonen est la possibilité d'intégration de données exogènes pouvant améliorer les résultats obtenus, notamment dans le cas des confusions de thèmes liées aux aspects topographiques. La classification basée sur les cartes topologiques de Kohonen servira à l'élaboration des cartes d'occupation du sol.

## 2. DESCRIPTION DU 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. Les données des images satellitaires utilisées sont celles issues du capteur TM prises le 15 mars 1993 à 9 h 45 et présentées par une fenêtre de 800 × 700 pixels sur les canaux bruts TM1 (bleu), TM3 (rouge) et TM4 (proche infrarouge). Des confusions apparaissent sur l'image à cause de l'effet d'ombre.

Un MNA (modèle numérique d'altitude) de la région a été utilisé pour extraire le paramètre pente (figure 2), représentant un facteur pouvant être important pour distinguer les thèmes différents présentant des réponses spectrales similaires sur les images satellitaires utilisées.

## 3. CARTES ORGANISATRICES DE KOHONEN

Les réseaux de type auto-organisateur de Kohonen sont des réseaux compétitifs et dynamiques, dans le sens où ils ont tendance à élire un neurone vainqueur et à le favoriser, d'une part, et à créer ou détruire des neurones, d'autre part (Université Paris-sud, 2002).

Le modèle de carte topologique proposé par Kohonen est un procédé d'auto-organisation qui va projeter les données initiales sur un espace discret et régulier de faible dimension (en général 1, 2 ou 3D). Les espaces utilisés sont des treillis réguliers dont chacun des nœuds est occupé par un neurone. La notion de voisinage entre les neurones découle alors directement de la structure et définit une topologie de la carte. Grâce au procédé d'auto-organisation, la topologie qui lie les données initiales est conservée au niveau des réponses proposées par le réseau (Kohonen, 1989 ; Thiria *et al.,* 1997).

À la manière des réseaux à compétition, les cartes topologiques de Kohonen sont constituées de deux couches :

– la couche d'entrée sert uniquement à la présentation des formes à classer et les états de tous ses neurones sont forcés aux valeurs des données d'entrée ;

– la couche d'adaptation est formée d'un treillis de neurones évoqué précédemment. Le choix de la géométrie du réseau employé est fait *a priori*. Les neurones utilisés à ce niveau sont des neurones linéaires, chacun d'entre eux étant branché à tous les éléments de la couche d'entrée. De manière à permettre le processus d'auto organisation, les poids qui lient les deux couches sont déterminés de manière adaptative.

### *3.1. Structure et fonctionnement*

Sur la figure 3, on représente le réseau organisé en une couche à une dimension. Chaque neurone $N_k$ est branché à un nombre $x_n$ d'entrées à travers n connexions plastiques de poids respectifs $W_c$.

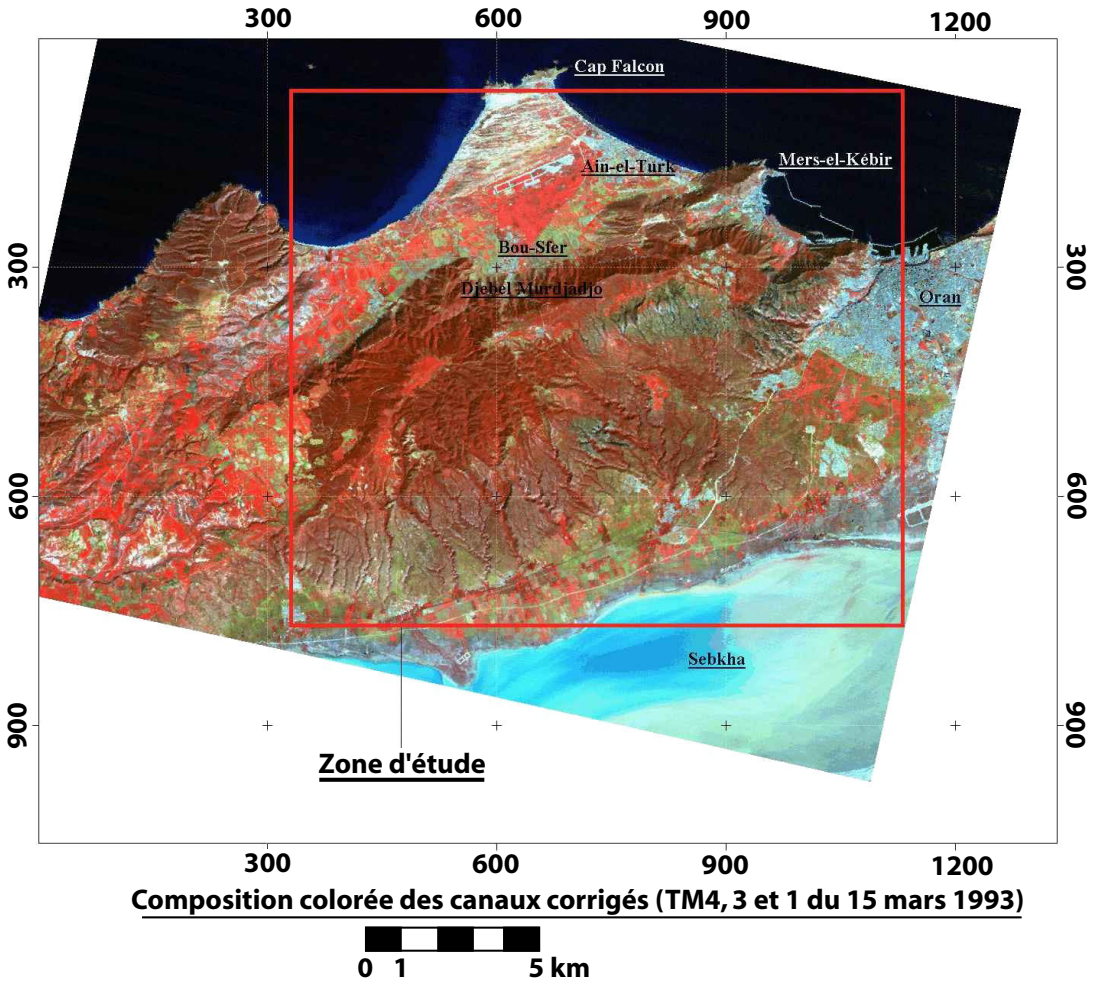



FIGURE 1 Localisation de la zone d'étude (Oran-Ouest). *Localisation of the studied area (West-Oran).*

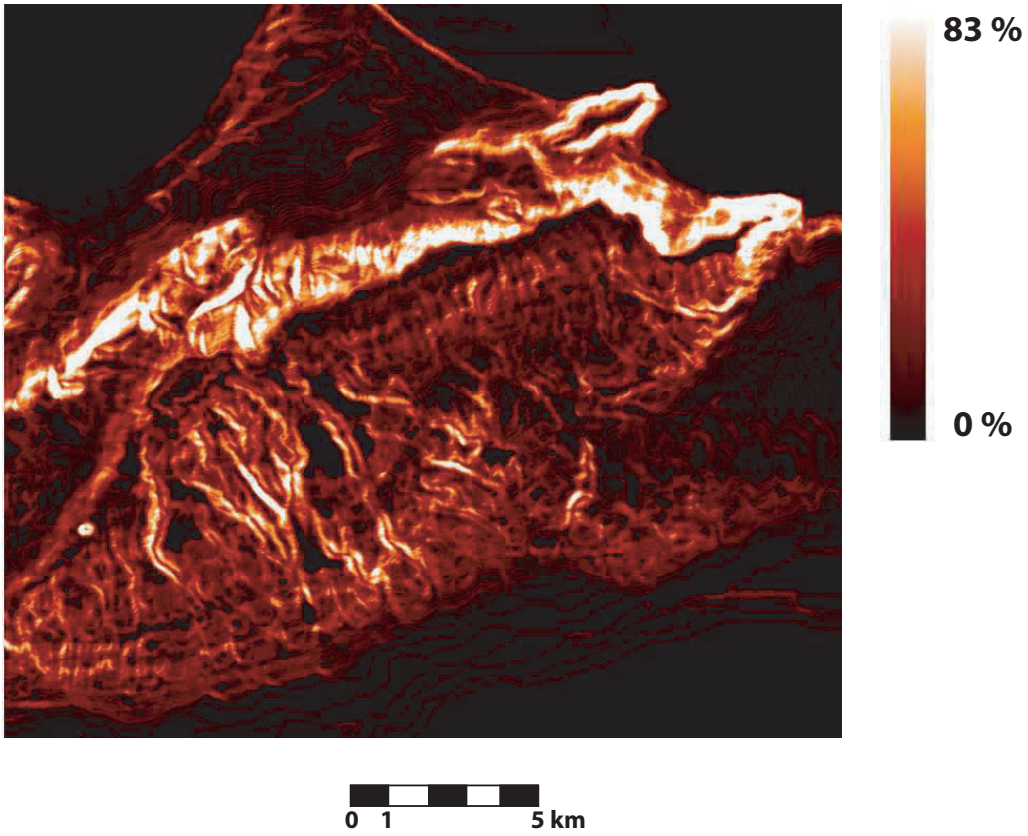



FIGURE 2 Image des pentes de la zone d'étude. *Slopes image of the studied area.*

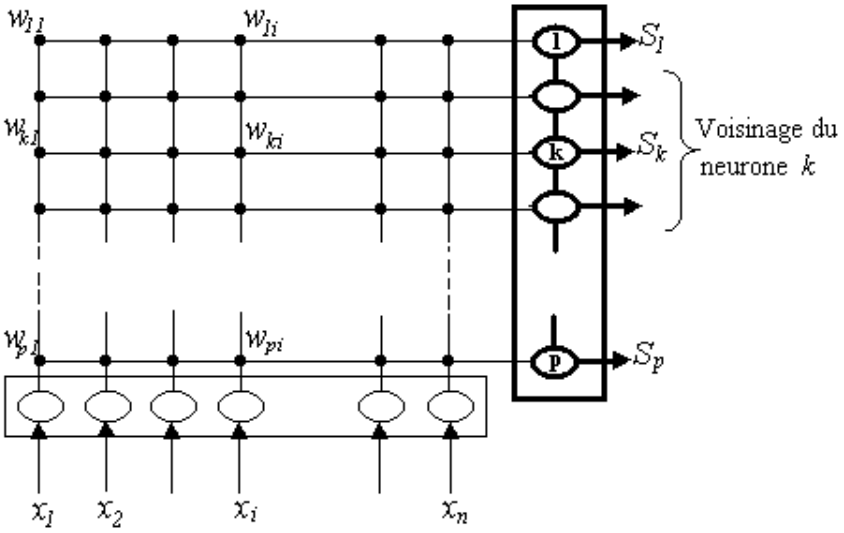



FIGURE 3 Architecture d'une carte auto-organisatrice (réseau 1D). *Architecture of a self-organizing map (Network 1D).*

À la présentation d'une entrée, un neurone sur la carte est sélectionné. Il correspond le plus possible à cette entrée de minimisation d'une distance. Le modèle de réseau neuronal proposé par Kohonen montre des propriétés d'auto-organisation et de représentation topologique de l'espace d'entrée (Touzet, 1992).

### 3.2. Apprentissage

Le principe d'un apprentissage compétitif est en général de favoriser le neurone vainqueur et ce en le rapprochant du vecteur d'entrée auquel il doit sa victoire.

L'algorithme d'apprentissage est dérivé de celui de Hebb (Touzet, 1992). Dans le cas où les exemples d'entrées sont sous la forme d'un ensemble ordonné d'apprentissage

$$E = \{X/X \in R^n\},$$

où chaque élément est étiqueté par un indice représentant cet ordre, l'algorithme est donné ci-dessous, avec c le neurone sélectionné, $V_C$ le voisinage et $W_i$ le vecteur de poids d'un neurone i :

début ;
taille du voisinage = nombre de neurones de la carte ;
initialiser le pas d'apprentissage $\alpha(t)$
et les vecteurs poids ;
pour t = 1 à $t_{max}$ faire ;
pour k = 1 à Card(E) faire ;
lire $X^{(k)} = (x_1, x_2, \ldots, x_m)^T$
calculer $\|X^{(k)} - W_c(t)\| = \min(\|X^{(k)} - W_c(t)\|)$ $i = 1..n$ (1)
si $i \in V_c(t)$, alors $W_i(t+1) = W_i(t) + \alpha(t)\,(X - W_i(t))$ (2)
sinon $W_i(t+1) = W_i(t)$ (3)
finsi;
finpour;
ajuster la taille du voisinage $V_c(t)$ et le pas
d'apprentissage $\alpha(t)$ $(0 < \alpha(t) < 1)$ ;
finpour ;
fin.

#### 3.2.1. Pas d'apprentissage

Le réseau se stabilise lorsque $W_i(t+1) = W_i(t)$.

À partir de la formule d'ajustement des poids :

$$W_i(t+1) = W_i(t) + \alpha(t)\,(X - W_i(t)),$$

nous avons :

$$W_i(t+1) = W_i(t)[1 - \alpha(t)] + \alpha(t)(X),$$

où $\alpha(t)$ est une fonction d'apprentissage qui décroît en général lentement et linéairement avec le temps $(0 < \alpha(t) < 1)$.

La stabilité est vérifiée quand :

$$\begin{cases} 1 - \alpha(t) = 1 \\ \wedge \\ \alpha(t)X = 0 \end{cases} \quad \Rightarrow \quad \alpha(t) \to 0$$

Sur la figure 4, on représente la fonction $\alpha(t) = e^{-t/T}$ pour les taux d'apprentissage suivants : T = 4, T = 6, T = 8 et T = 10.

Pour une valeur assez grande de T, l'adaptation est lente et, par conséquent, $\alpha(t)$ tend vers zéro lentement, ce qui induit un bon apprentissage. En revanche, des faibles valeurs de T entraînent une convergence rapide et, de ce fait, le réseau peut oublier ce qu'il a déjà appris.

#### 3.2.2. Ajustement du voisinage et du pas d'apprentissage

Nous présentons ici quelques variantes liées au choix de la fonction de voisinage et au pas d'apprentissage.

Les équations 2 et 3 peuvent s'écrire sous la forme suivante :

$$W_i(t+1) = W_i(t) + \alpha(t)\, NB(i,c,t)\, (X - W_i(t))$$

$$\text{où} \begin{cases} NB(i,c,t) = 1 & \text{si} \quad i \in V_c(t) \\ 0 & \textit{sinon} \end{cases}$$

$NB(i,c,t)$ est appelée fonction de voisinage.

En général, elle est choisie, comme pour le pas d'apprentissage, décroissante en $\boldsymbol{t}$ et variant inversement avec la distance mesurée sur la carte entre le neurone $\boldsymbol{i}$ et le neurone $\boldsymbol{c}$. Pham et Bayro Corrochano (1994) ont proposé les formes suivantes pour $\alpha(t)$ et $NB(i,c,t)$ :

$$\alpha(t) = K_1\, e^{-t/T1} \text{ et } NB(i,c,t) = K_{2c,i} + K_{3,c,i}\, e^{-t/T2}$$

où $K_1$, $T_1$ et $T_2$ sont des constantes, $K_2$ détermine la valeur maximale pour $\alpha(t)$ et $T_1$ le taux d'affaiblissement de $K_{2c,i}$ et $K_{3,c,i}$ définissent les limites du voisinage du neurone $c$ et $T_2$ (très inférieur à $T_1$) détermine le taux de réduction de ce voisinage.

Stewart *et al.* (1994) ont suggéré une forme gaussienne pour $NB(i,c,t)$ et une forme linéaire pour $\alpha(t)$ :

$$NB(i,c,t) = e^{\frac{-(i-c)^2}{2s^2(t)}}$$

$$\sigma(t+1) = 1 + [\sigma(0) - 1]\,\frac{t_{max} - t}{t_{max}}$$

$$\sigma(t) = \sigma(0)\,\frac{t_{max} - t}{t_{max}}$$

où $t_{max}$ est le nombre total d'itérations, $\alpha(t)$ et $\sigma(t)$ sont respectivement des valeurs initiales pour $\alpha(t)$ et $\sigma(t)$.

## 4. CALIBRATION

La calibration de la carte consiste à libeller ou à étiqueter chacun de ses neurones par la classe thématique correspondante. C'est une étape qui suit celle de l'apprentissage et se fait en mode dirigé.

On dispose d'un échantillon d'observations pour chaque classe thématique. La construction des échantillons est basée sur le fait que les objets d'une même classe thématique ont des réponses spectrales relativement limitées dans des intervalles donnés.

Notons $E_j$ l'échantillon de la classe thématique $CT_j$ pour $j = 1..J$ et $J$ étant le nombre de classes. La procédure de calibration se résume ainsi :

début ;
pour j = 1 à J faire ;
lire $X = (x_1,x_2,\ldots,x_m)^T$ de l'échantillon $E_j$ ;
sélectionner parmi tous les neurones de la carte celui le plus activé pour cette entrée;
libeller le neurone par la classe thématique $CT_j$ ;
finpour ;
fin.

En déroulant cet algorithme, on remarque bien qu'une classe thématique sera décrite par un ou plusieurs neurones appartenant à la même région de la carte, et donc par un ou plusieurs vecteurs prototypes.

## 5. APPLICATION

L'application est basée sur un ensemble de tests pour la détermination des paramètres optimaux du réseau. Ces paramètres sont utilisés pour la réalisation de la classification, d'abord avec uniquement les données images et ensuite avec l'intégration des données de pente extraites du MNA.

### *5.1. Base d'apprentissage*

La base d'apprentissage du réseau est constituée d'un ensemble de pixels provenant des différentes bandes spectrales (TM1, TM3 et TM4) issues de l'image à classer et de la donnée de pente lorsque celle-ci est utilisée. La sélection de cet ensemble peut être faite par un tirage aléatoire ou systématique aléatoire.

Le mode systématique aléatoire a été choisi pour permettre une représentation plus équitable de toute l'image et donc produire un ensemble de pixels bien représentatif des classes présentes dans l'image. Ce type d'échantillonnage consiste à diviser l'image multibande au moyen d'une grille (figure 5) et à choisir aléatoirement un pixel dans chaque case.

La taille des cases détermine le taux d'échantillonnage.

### *5.2. Paramétrage du réseau*

Le pas d'adaptation $\alpha(t)$ choisi est donné par la formule suivante :

$$\alpha(t) = k\ e^{-t/T}$$

où k = 0,5, T est le taux d'apprentissage et t est le pas d'apprentissage.

Nous remarquons, qu'avec k = 0,5, l'adaptation du réseau lors de la phase d'apprentissage devient plus lente et, de ce fait, on obtient une meilleure identification des différents noyaux des classes à rechercher.

L'ajustement des poids initiaux entre le vecteur d'entrée et le vecteur de sortie se fait suivant un échantillonnage systématique aléatoire.

La taille du voisinage est fixée au nombre de neurones de la couche de sortie.

Le nombre d'itérations t s'accroît avec un pas de 10 pour chaque test effectué.

### *5.3. Tests réalisés*

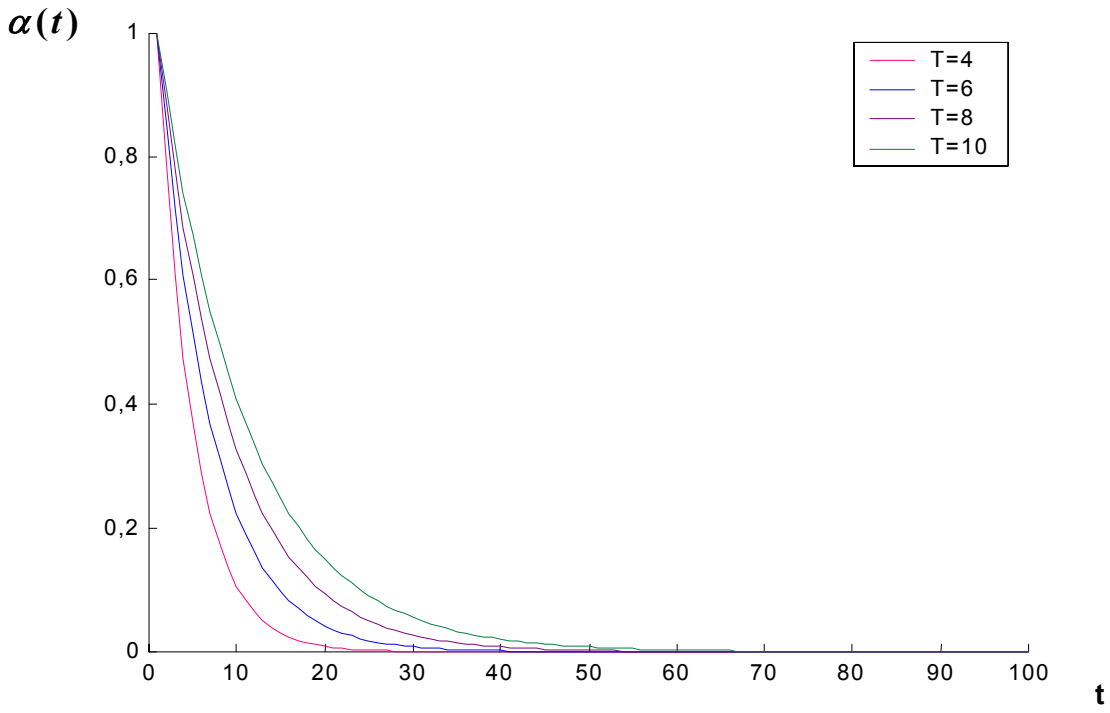
Plusieurs tests ont été effectués en jouant sur les différents paramètres ayant une incidence sur le résultat final : le taux d'apprentissage T, le nombre d'itérations t et le taux d'échantillonnage.

Ces tests ont permis de déterminer les valeurs optimales des paramètres du réseau en fixant un intervalle dans lequel sont prélevées celles qui seront utilisées avec le taux d'échantillonnage choisi. Pour une taille de voisinage égale à 20, l'intervalle des valeurs sélectionné est de 8 à 10 pour le taux d'apprentissage T et de 60 à 100 pour le pas d'apprentissage t. Notons que ces tests sont réalisés avec une phase de calibration incluant les thèmes suivants : eau, céréaliculture, maraîchage, jachère, forêt maquis, sol nu et sable, zones urbaines et sebkha.

Sur la figure 6, on présente l'organigramme méthodologique général utilisé pour les différentes classifications réalisées.

Le logiciel ENVI (*Environment for Visualizing Images*) a été utilisé pour l'extraction du fichier pente et les fichiers images ainsi que pour les corrections géométriques (modélisation polynomiale). La mise en forme de la carte d'occupation du sol a été effectuée sous CORELDRAW.

Tous les traitements inhérents à ce travail ont été réalisés sur un PC Pentium II.




T = taux d'apprentissage
t = nombre d'itérations
α (t) = pas d'apprentissage

FIGURE 4 Évolution du pas d'apprentissage en fonction de t. *Learning step variation versus t.*

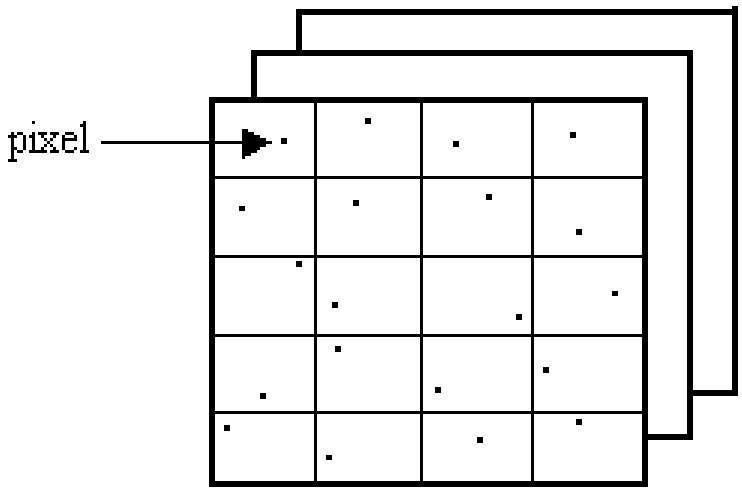



FIGURE 5 Grille associée à l'image multibande. *Grid related to the multispectral image.*

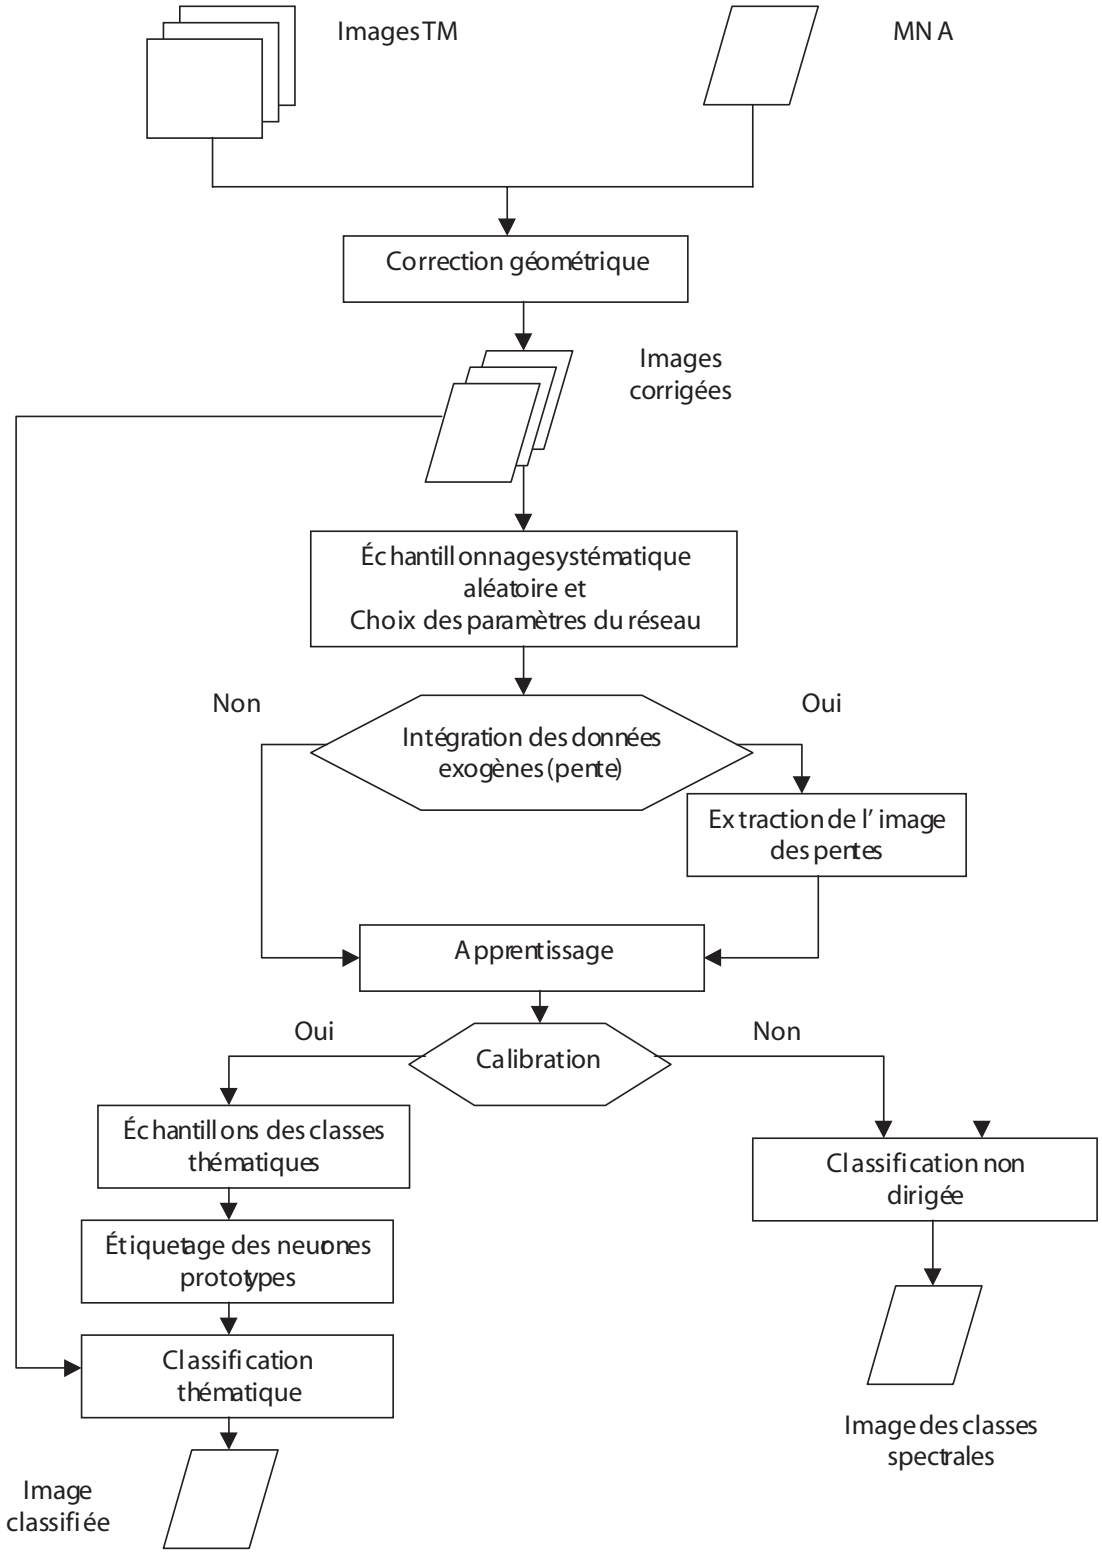



FIGURE 6 Organigramme méthodologique. *Methodological flow chart.*

## 6. RÉSULTATS ET DISCUSSION

Les tests retenus (tableau 1) ont été réalisés avec une taille de voisinage égale à 20, un taux d'apprentissage T égal à 8 et le nombre d'itérations t compris entre 60 et 100. Ces paramètres ont été combinés avec différents taux d'échantillonnage.

TABLEAU 1 Tableau des tests retenus pour la réalisation de la classification. *Table of the tests retained for the realization of the classification.*

| N° | t | Maille | Pente |
|---|---|---|---|
| 1 | 60 | 1 × 1 | ☐ |
| 2 | 60 | 10 × 10 | ☐ |
| 3 | 80 | 1 × 1 | ☐ |
| 4 | 80 | 10 × 10 | ☐ |
| 5 | 100 | 1 × 1 | ☐ |
| 6 | 100 | 10 × 10 | ☐ |
| 7 | 60 | 1 × 1 | ☒ |
| 8 | 60 | 10 × 10 | ☒ |
| 9 | 80 | 1 × 1 | ☒ |
| 10 | 80 | 10 × 10 | ☒ |
| 11 | 100 | 1 × 1 | ☒ |
| 12 | 100 | 10 × 10 | ☒ |

La même série de tests pour la classification a été d'abord réalisée avec uniquement les données images et ensuite avec l'intégration des données pente extraites du MNA.

Concernant les tests (1, 3, 5) et (2, 4, 6) dont chaque série est réalisée avec un taux d'échantillonnage constant et un accroissement du pas d'apprentissage de 20, une amélioration a été remarquée concernant les classes sebkha, zones urbaines et maraîchage.

Cette amélioration est due principalement à l'accroissement de la valeur de t. En effet, une valeur assez grande de t permet un meilleur apprentissage, induisant ainsi une séparabilité des noyaux relatifs aux classes recherchées, ce qui décroît le taux d'erreur lors de l'affectation du pixel à la classe associée. Il est à noter, qu'à partir d'une valeur de t supérieure à 90, les tests donnent pratiquement les mêmes résultats.

Pour ce qui est des tests (1, 2), (3, 4) et (5, 6) pour lesquels le taux d'échantillonnage passe de 1 × 1 à 10 × 10, cette variation n'influe pas de façon significative du fait que les différents thèmes sur les images à classifier représentent une densité relativement importante. Pour l'aspect thématique des résultats obtenus, nous constatons une confusion entre la tache d'ombre et la classe eau pour les différents tests effectués.

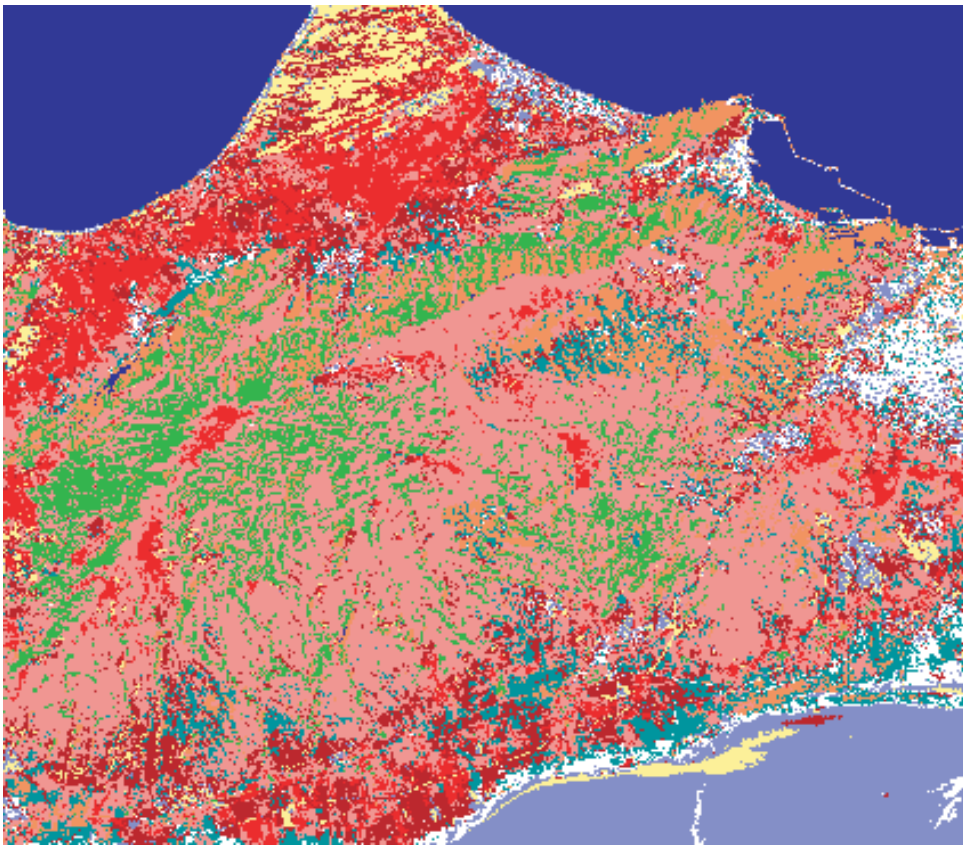
Cette situation nous a amenés à intégrer la donnée exogène de pente issue du MNA afin de pouvoir y remédier. Les résultats obtenus pour les tests (7, 9, 11), avec un taux d'échantillonnage fixé à 1 × 1, s'améliorent à t = 80 avec la disparition de la confusion entre la tache d'ombre et la classe d'eau ainsi qu'une meilleure distinction entre la sebkha et les zones urbaines. De même que précédemment, les mêmes constatations restent valables avec un affinage des classes en sortie pour les tests (8, 10, 12). L'amélioration constatée dans ce dernier cas est certainement due au taux d'échantillonnage utilisé impliquant une meilleure représentativité des principaux thèmes de l'image par rapport au cas précédant où tous les pixels de l'image ont été pris.

Sur les figures 7 et 8, on présente les résultats des tests 4 et 10 (tableau 1) obtenus par classification utilisant les mêmes paramètres dans les deux cas, avec ou sans intégration des données de pente.

L'image classifiée obtenue au test 9, après regroupement en sept classes thématiques, servira à l'élaboration de la carte d'occupation du sol de la région Oran-Ouest (figure 9).

Le paramétrage du réseau reste une tâche fastidieuse du fait qu'il dépend étroitement des données à inclure dans la phase d'apprentissage. De plus, les tests réalisés montrent très bien que les différents choix de ces paramètres entraînent différents résultats. Cependant, la capacité du réseau à intégrer des données exogènes permet de lever certaines confusions entre thèmes proches radiométriquement et différents topographiquement.

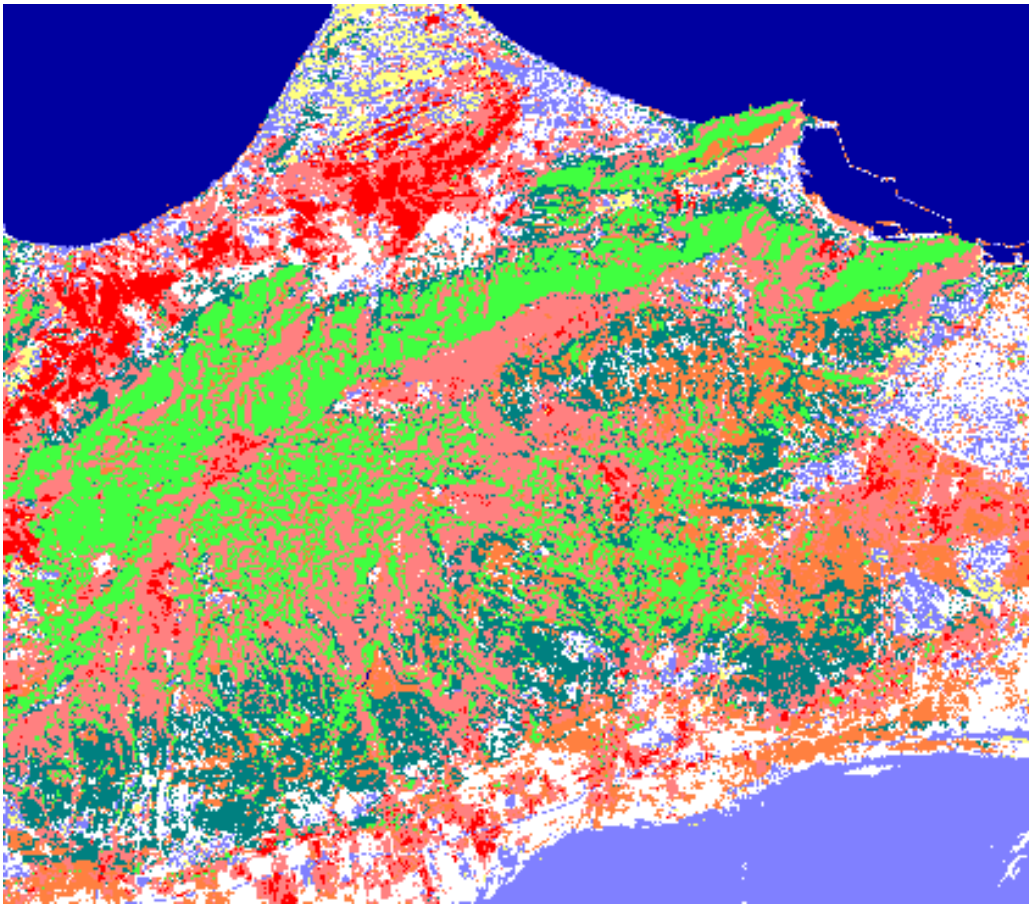
Cette possibilité d'intégration de données multisources permet d'avoir des résultats meilleurs que ceux obtenus par les méthodes classiques qui ne prennent en compte que des données radiométriques. Les classes thématiques finales représentées sur la carte d'occupation du sol (figure 9) sont globalement conformes à la réalité de terrain, abstraction faite de certaines confusions constatées entre les deux classes sebkha et zones urbaines.






| CLASSE | COULEUR |
|---|---|
| Eau | |
| Zones urbaines | |
| Brûlis | |
| Jachères | |
| Maraîchage | |
| Céréaliculture | |
| Forêt | |
| Maquis | |
| Sol nu et sable | |
| Sebkha | |

FIGURE 7 Image obtenue par classification (test 4). *Image obtained by classification (Test 4).*



0 1 5 km

| CLASSE | COULEUR |
|---|---|
| Eau | |
| Zones urbaines | |
| Brûlis | |
| Jachères | |
| Maraîchage | |
| Céréaliculture | |
| Forêt | |
| Maquis | |
| Sol nu et sable | |
| Sebkha | |

FIGURE 8 Image obtenue par classification (test 10). *Image obtained by classification (Test 10).*

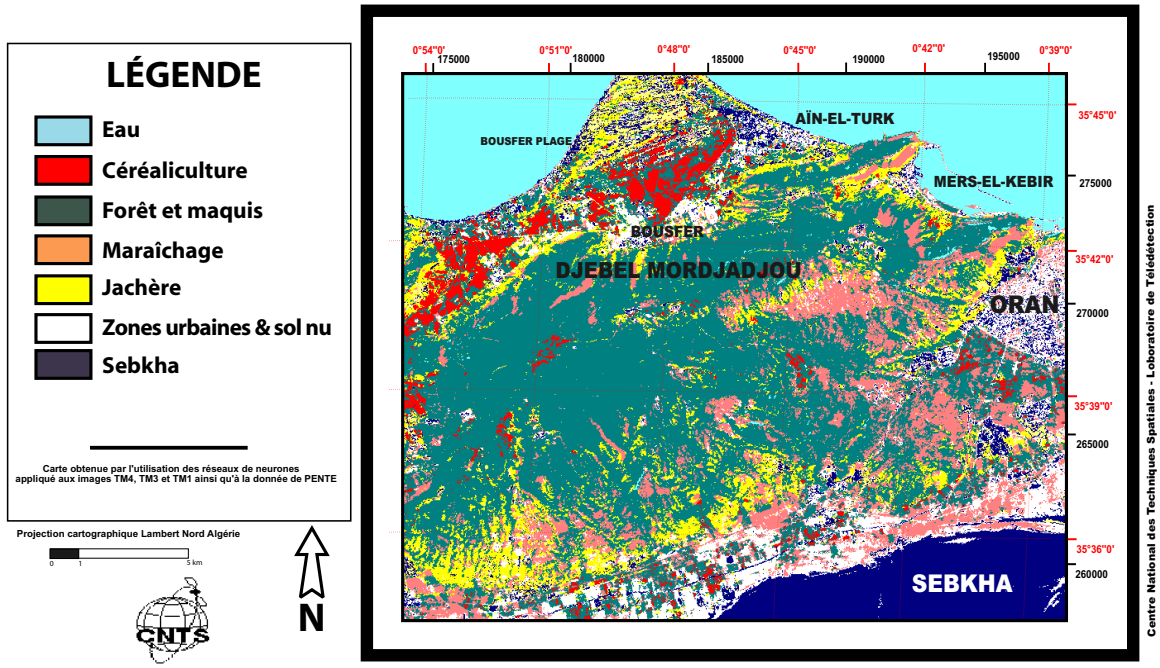



FIGURE 9 Carte d'occupation du sol de la région Oran-Ouest. *Land cover map of West-Oran.*

## 7. CONCLUSION

L'utilisation du réseau de Kohonen est sensible au changement des paramètres internes tel que le taux d'apprentissage, le nombre d'itérations, le nombre de neurones et le voisinage. Le taux d'échantillonnage peut aussi influer sur les résultats puisque les régions les plus représentées en entrée occuperont des domaines plus larges en sortie.

La manière de fixer ces paramètres est critique pour la convergence du réseau vers un état stable permettant de bons résultats. Néanmoins, ceci n'exclut en aucun cas sa fiabilité dans les domaines de la classification multisource pour la distinction de certains thèmes qui semblent confondus dans les résultats rendus par les classifications classiques. Cette possibilité est importante dans la classification des thèmes présentant des réponses spectrales similaires lorsqu'il s'agit de situations complexes : topographie accidentée, confusion de thèmes et ombrage. Comme suite à ce travail et afin de parvenir à une amélioration éventuelle des résultats obtenus avec cette approche, il est prévu d'intégrer d'autres paramètres (altitude et exposition) issus d'un MNA.

En perspective, il est envisagé d'utiliser la version dirigée de l'algorithme de Kohonen, appelé LVQ (*Learning Vector Quantization*), dont le principe est de déplacer itérativement les vecteurs prototypes de façon à les éloigner des surfaces de décision entre les classes. Cette perspective permettra d'aborder l'aspect précision puisque l'on se situera réellement dans un environnement dirigé.

### *Références bibliographiques*

Jodouin, J.F. (1994) Les réseaux de neurones, principes et définitions. Hermès, Paris, 124 p.

Kohonen, T. (1989) Self organisation and associative memory. 3e édition, Springer-Verlag, Berlin, 312 p.

Lambert, E. (1999) Étude des techniques d'optimisation et de différents réseaux de neurones appliqués à la séparation de signaux en traitement du signal : Application à l'approximation de fonctions multivariables. Mémoire de DEA, Université de Haute-Alsace, Mulhouse, 58 p.

McCulloch, W. S and Pitts, W. (1943) A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, vol. 9, p. 127-147.

Pham, D. T. and Bayro Corrochano, E. J. (1994) Self-Organizing neuronal network based pattern clustering method with fuzzy outputs. Pattern Recognition, vol. 27, n° 8, p. 1103-1110.

Stewart, C., Lu, Y.-C. and Larson, V. (1994) A neuronal clustering approach for high resolution radar target classification. Pattern recognition, vol. 27, n° 4, p. 503-513.

Thiria, S., Lechevalier, Y., Gascuel, O. et Canu, S. (1997) Statistique et méthodes neuronales. Éditions Dunod, Paris, 336 p.

Touzet, C. (1992) Les réseaux de neurones artificiels. Introduction au connexionisme ; cours, exercices et travaux pratiques. LERI, Nîmes, 127 p.

Université Paris-Sud (2002) Les réseaux de neurones. http://www.ie2.u- psud.fr/~ coutris/neural/neu8.html.

Zahzah, E. (1992) Contribution à la représentation des connaissances et à leur utilisation pour interprétation automatique des images satellite. Thèse de doctorat, Université Paul Sabatier de Toulouse, IRIT, 284 p.