CLASSIFICATION MULTISOURCE NON DIRIGÉE À L'AIDE DE L'ALGORITHME GROWING NEURAL GAS « GNG » : APPLICATION À UNE IMAGE ETM$^+$ DE LANDSAT-7 DE LA RÉGION D'ORAN, EN ALGÉRIE

Habib MAHI[1], Djaffar YOUSFI[1] et Tahar IFTENE[2]

[1] Centre national des techniques spatiales, 01, avenue de la Palestine, B.P. 13, 31200, Arzew, Algérie, Téléphone : +213-41-47-25-79 ; télécopieur : +213-41-47-36-65 ; courriel : mahihabib@yahoo.fr ; yousfi_djaffar@yahoo.fr
[2] Agence spatiale algérienne, 14, rue Omar Aissaoui, El Hammadia, Bouzaréah, Alger, 16006, Algérie, Téléphone : + 213 21 94 11 07 / 02 ; télécopieur : + 213-21-94-10-50 ; courriel : tiftene@mail.asal.dz

Soumis le 20 novembre 2006 ; révisé le 8 mars 2007 ; accepté le 16 avril 2007- © *Revue Télédétection*, 2007, vol. 7, n° 1-2-3-4, p. 485-497

Résumé

Les algorithmes de classification classiques sont parfois loin de rivaliser avec le photo-interprète humain. Plusieurs classifieurs en mode dirigé ou non dirigé, fondés sur l'analyse purement spectrale des pixels, ont été proposés et testés (maximum de vraisemblance, nuées dynamiques, etc.). Mais, l'information spectrale n'est pas toujours suffisante pour distinguer les objets en confusion et, globalement, les résultats obtenus ne sont pas toujours satisfaisants. Ceci reste valable même lors du choix des bandes supposées les plus pertinentes en vue d'une meilleure identification des objets en confusion. Partant de ce constat, il apparaît clair que la description exhaustive du comportement spectral des pixels exige parfois l'utilisation de données auxiliaires. C'est dans ce cadre que s'inscrit cet article. On propose un classifieur fondé sur l'algorithme Growing Neural Gas *à apprentissage non dirigé et intégrant des données provenant de sources différentes. L'objectif de cette méthode est d'élaborer une classification multisource en combinant, avec des données multibandes ETM$^+$ de Landsat-7, des données RSO d'ERS-2 ainsi que des données de pente associées provenant d'un modèle numérique d'altitude, et ce en vue d'obtenir une carte d'occupation des terres reflétant la réalité de terrain.*

Mots-clés : Classification, réseaux de neurones, algorithme *Growing Neural Gas*, donnée multisource, pente, modèle numérique d'altitude, occupation des terres.

UNSUPERVISED MULTISOURCE CLASSIFICATION USING THE GROWING NEURAL GAS ALGORITHM « GNG » : APPLICATION TO AN ETM+ IMAGE OF THE ORAN REGION (ALGERIA)

Abstract

The traditional classification algorithms are sometimes far from competing with the human photo-interpreter. Several classifiers in supervised or unsupervised mode based on the purely spectral analysis of the pixels, were suggested and tested (maximum likelihood, ISODATA, etc.). However, the spectral information is not always sufficient, and, overall, the results obtained are not always satisfactory. This remains valid even in certain cases, in particular at the time of the judicious choice of the most relevant bands, for a better discrimination of the objects in confusion. On the basis of this paper, it appears clear that the exhaustive description of the pixel behaviour sometimes requires the use of auxiliary data in addition to the spectral information. This paper is proposed within this framework. We propose a classifier based on the Growing Neural Gas algorithm using unsupervised learning and integrating the data from different sources. The objective of this methodology is to carry out a multisource classification combining multispectral Landsat-7 ETM$^+$ data, ERS-2 SAR data and associated slope data derived from a Digital Elevation Model in order to obtain a land cover map accurately reflecting the ground truth.

Key words: Classification, Neural Networks, Growing Neural Gas algorithm, multisource data, Slope, Digital Elevation Model, Land cover map.

1. INTRODUCTION

Les données satellitaires, qui sont la réponse spectrale d'un objet au sol, sont parfois entachées d'erreurs dues à l'influence de plusieurs paramètres physiques : atmosphère, configuration des capteurs, topographie accidentée, etc., induisant parfois quelques confusions lors de leur traitement, plus particulièrement celui de la classification. L'intégration de données auxiliaires s'avère essentielle afin de remédier à cet aléa. Néanmoins, cette intégration présente un second souci majeur. En effet, les données provenant de différentes sources peuvent ne pas avoir le même « référentiel », soit au plan des lois de distribution, soit au plan du codage des données elles-mêmes. Cette carence rend les techniques de classification classiques (maximum de vraisemblance, ISODATA, etc.) inefficaces (Yin and Allinson, 2001). Diverses méthodes ont été mises en œuvre afin de pallier un tel problème, notamment l'approche dite par réseaux de neurones (Iftene *et al*., 2003 ; Zahzah, 1992 ; Besse, 2005).

En effet, et depuis la première modélisation du neurone biologique par Mc Culloch et Pitts, en 1943 (McCulloch and Pitts, 1943), les réseaux de neurones ont connu un essor grandissant et ils sont abondamment utilisés dans plusieurs domaines : approximation des fonctions, prédiction des séries temporelles, reconnaissance des formes ainsi que classification et segmentation d'images. Cette émergence est liée tant à leur capacité de traitement des données incomplètes, incertaines ou bruitées (Jodouin, 1994 ; Touzet, 1992), qu'à leur aptitude à résoudre des problèmes insolubles avec des techniques informatiques traditionnelles ou au moins à rendre le coût de cette solution de problèmes acceptable en fonction de certains critères, comme le temps de convergence.

L'objectif du présent article est de tester un nouveau classifieur neuronal à apprentissage non dirigé pour élaborer la carte d'occupation des terres de la région d'Oran. L'algorithme proposé a la particularité d'être constructif, d'où l'appellation *Growing Neural Gas* (GNG). De plus, comme les algorithmes de la même famille, il permet d'intégrer plusieurs données provenant de sources diverses.

2. SITE D'ÉTUDE ET DONNÉES UTILISÉES

Le site d'étude est la région d'Oran, en Algérie, qui s'étend entre 0° 56' à 0° 25' de longitude est et 35 °32' à 35 °52' de latitude nord (figure 1).

Les données satellitaires utilisées pour représenter l'occupation des terres de la zone d'étude sont celles provenant du capteur ETM$^+$ de Landsat-7, acquises le 12 février 2002 et présentées par une fenêtre de 1 259 x 700 pixels sur les bandes 1 (bleu), 3 (rouge) et 4 (proche infrarouge). La résolution spatiale est de 30 x 30 m. L'analyse statistique de ces données révèle la diversité des thèmes existants. Hormis, le thème « Mer », qui est facilement mis en évidence sur l'image, beaucoup d'autres thèmes présentent une similitude des réponses spectrales, ce qui implique quelques confusions entre ces thèmes. Les 11 thèmes les plus fréquents sont les suivants : « Mer », « Céréaliculture », « Maraîchages », « Jachères », « Maquis exposé », « Maquis non exposé », « Zone bâtie », « Sebkha », « Sol nu », « Sable » et « Brûlis ».

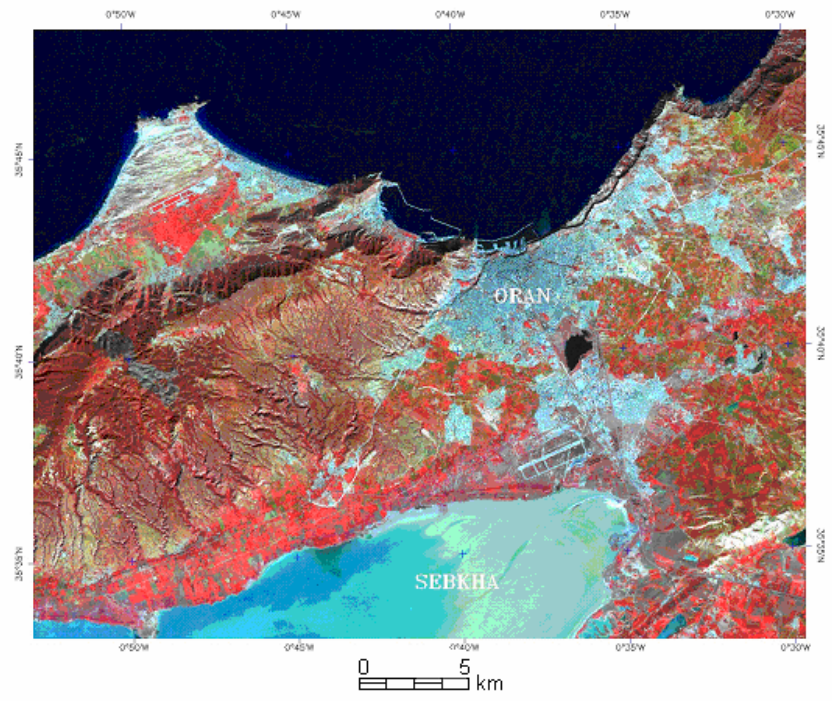


Figure 1 : Composition colorée des bandes ETM$^+$ 4, 3, 1 du 12 février 2002. *Colour composition of the ETM+ 4, 3, 1 bands of February 12, 2002.*

3. MÉTHODOLOGIE

On présente d'abord l'algorithme GNG et les tests effectués sur une base d'apprentissage afin de définir les paramètres optimaux à utiliser dans l'étape de classification. L'approche préconisée et la description des données exogènes sont abordées.

3.1. Réseau GNG

Le GNG est un réseau constructif à apprentissage non dirigé qui ne pose a priori aucune hypothèse sur la topologie de l'espace des entrées (Holmstöm, 2002 ; Parizeau, 2006), qui est le lien entre les données en entrée. Un réseau à deux neurones est d'abord créé et de nouveaux neurones ainsi que de nouvelles connexions entre les neurones sont ajoutés au fil de l'apprentissage. La topologie du réseau est représentée par un graphe $G=[V(t), E(t)]$, où $V(t)$ désigne l'ensemble des sommets du graphe à l'instant t et $E(t)$ l'ensemble de ses arêtes. À chaque sommet est associé un neurone caractérisé par son vecteur poids synaptique w_i ainsi qu'un vecteur d'erreur e_i. Ce dernier sert à accumuler l'erreur de modélisation attribuable au neurone i et guide le choix de l'emplacement où l'on ajoute périodiquement de nouveaux sommets dans le graphe. À chaque connexion « arête » entre le neurone i et le neurone j est associé un âge $a_{i,j}$. Un jeune âge implique une vraisemblance élevée de la relation topologique et, inversement, un âge dépassant un certain seuil signifie une vraisemblance faible de cette relation etm par conséquent, elle disparaît du graphe.

3.2. Algorithme

L'application de l'algorithme se fait en sept étapes.

Au point de départ, il faut :

1) initialisation : $V=\{x,y\}$ et $E=\{\{x,y\}\}$ avec $w_x(0)$ et $w_y(0)$ initialisés aléatoirement avec des petits poids synaptiques dans l'espace des entrées ; $e_x(0)=e_y(0)=a_{x,y}(0)=0$;

2) fixer t_{max}, τ, η_g, η_v, a_{max} et α ;

3) $t=1$;

4) répéter tant que $t\leq t_{max}$.

La deuxième étape consiste à choisir aléatoirement un échantillon $p(t)$ parmi l'ensemble d'apprentissage, $p(t)$ étant une matrice dont le nombre de lignes représente le nombre de pixels de la base d'apprentissage et le nombre de colonnes est égale au nombre de mesures disponibles pour chaque pixel.

La troisième étape consiste à déterminer les deux neurones gagnants g_1 et g_2 les plus près de $p(t)$, soit :

$$g_1 = \arg \min_{i \in V(t)} \left\| p(t) - w_i(t) \right\| ;$$

$$g_2 = \arg \min_{i \in V(t) \wedge i \neq g_1} \left\| p(t) - w_i(t) \right\|.$$

La quatrième étape consiste à augmenter les âges de toutes les connexions adjacentes à g_1, soit

$$\forall \{i, g_1\} \in E: \; a_{i,g_1} = a_{i,g_1} + 1.$$

La cinquième étape consiste à augmenter l'erreur associée au premier gagnant :

$$e_{g_1} = e_{g_1} + \left\| p(t) - w_{g_1}(t) \right\|.$$

La sixième étape consiste à déplacer les vecteurs de poids synaptiques de g_1 et de ses voisins immédiats dans la direction de $p(t)$, soit :

$$\Delta w_{g1}(t) = \eta_g \left[p(t) - w_{g1}(t) \right]$$

$$\Delta w_v(t) = \eta_v \left[p(t) - w_v(t) \right], \; v \in \left\{ i \in V \middle| i \neq g_1 \text{ et } \{i, g_1\} \in E(t) \right\}$$

si $\{g_1, g_2\} \in E$, alors $a_{g_1,g_2} = 0$; sinon $E(t) = E(t) \cup \{\{g_1, g_2\}\}$, $a_{g_1,g_2} = 0$.

La septième étape consiste à retirer de E toutes les connexions pour lesquelles $a_{i,j} > a_{\max}$ et à retirer aussi tous les neurones qui se retrouveraient isolés (sans aucune connexion). Si $(t \bmod \tau) = 0$, alors :

- il faut déterminer le neurone q possédant l'erreur maximale, soit :

$$q = \arg \max_{i \in V} e_i \ ;$$

- il faut déterminer le neurone r , voisin de q , possédant aussi l'erreur maximale, soit :

$$r = \arg \max_{i \in \{i \in V \mid i \neq q \text{ et } \{i,q\} \in E(t)\}} e_i \ ;$$

- il faut insérer un nouveau neurone x à mi-chemin entre q et r , soit :

$$w_x(t) = \frac{w_q(t) + w_r(t)}{2} \ ; \ e_x = \frac{e_q}{2}, \ e_q = \frac{e_q}{2} \ ;$$

- il faut remplacer la connexion $\{q,r\}$ par les deux connexions $\{q,x\}$ et donc :

$\{x,r\}$ avec $a_{q,x} = a_{x,r} = 0$;

- il faut réduire les signaux d'erreur de tous les neurones, soit :

$$e_i = \alpha e_i, \ \forall i \in V(t) .$$

$$t = t + 1.$$

Fin.

3.2. Discussion

La détection des nœuds couvrant une large portion de l'espace d'entrée, synonyme de la non représentativité optimale de la distribution initiale, est donnée par l'erreur locale cumulée e . En effet, dans un premier temps, la valeur de cette mesure statistique augmente, afin de trouver les nœuds gagnants avec un champ attractif large. Cette erreur sera mise à jour après insertion d'un nouveau nœud médian. L'intervalle du nœud aura donc un petit écart type et sera donc plus représentatif des données qui lui sont appropriées. Sur la figure 2, on présente le principe d'insertion d'un nouveau nœud sur une base d'apprentissage formée de cinq classes.

Pour ce qui est des mouvements des nœuds, le nœud gagnant g est translaté le long de la différence scalaire entre le vecteur de référence et le vecteur d'entrée $\left(p(t) - w_{g1}(t)\right)$ afin de le rapprocher du vecteur d'entrée auquel il doit sa victoire. La valeur scalaire η_g est comprise entre 0 et 1. La linéarité de la translation va encourager le nœud en le rapprochant du vecteur d'entrée. Les nœuds voisins subissent la même translation avec une valeur scalaire notée $\eta_v < \eta_g$. L'insertion des nœuds est fonction de la constante τ . Un τ faible encourage la création de plusieurs nœuds engendrant ainsi une sur-représentativité des différentes régions. Par contre, une valeur modérée rend l'insertion plus lente en permettant un meilleur positionnement à l'intérieur des régions. Sur la figure 3, on constate, qu'à τ = 150, 12 nœuds sont créés et, sur la figure 4, on remarque, qu'à τ = 200, seulement 9 nœuds sont créés.

La constante $a_{\max}$ conditionne le maintien ou la suppression d'un lien (arête) entre deux nœuds. Les liens dont l'âge est supérieur à $a_{\max}$ seront détruits.

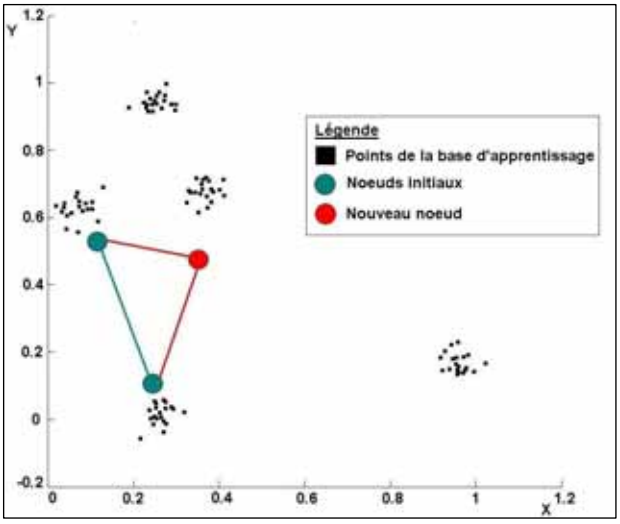


Figure 2 : Principe d'insertion d'un nouveau nœud. *Principle of the insertion of a new node*.

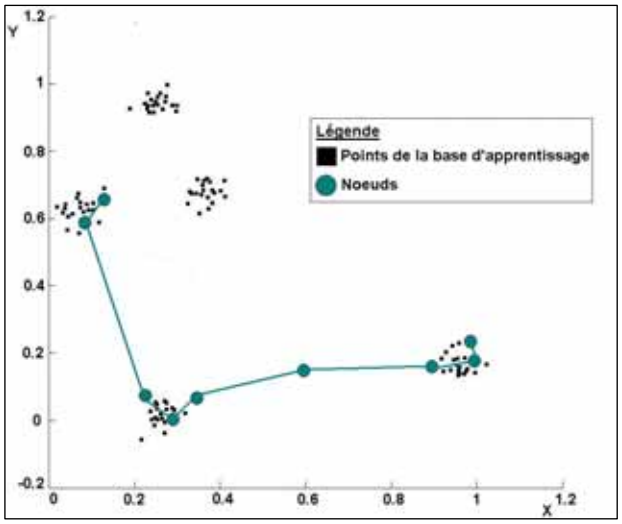


Figure 3 : État de l'algorithme GNG après τ = 200, 9 nœuds créés. *The state of the GNG algorithm after* τ *= 200, 9 nodes created*.

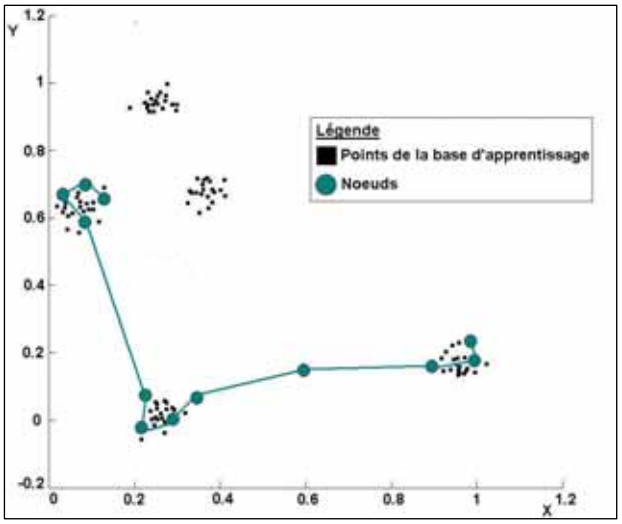


Figure 4 : État de l'algorithme GNG après τ = 150, 12 nœuds créés. *The state of the GNG algorithm after* τ *= 150, 12 nodes created*.

3.3. Simulation

Afin d'identifier les paramètres optimaux du réseau GNG, deux séries de tests ont été effectuées sur un ensemble de données de 90 points. Cette base est formée de trois grandes classes. Le nombre de neurones recherchés est fixé à 9, $\tau = 100$, avec une variation de t_{max} dans l'ensemble $\{90, 120, 150\}$.

La première série de tests est réalisée à partir d'un tirage séquentiel. Dans ce mode de tirage, on présente tous les représentants de la classe 1, puis de la classe 2 et de la classe 3. La seconde série est réalisée à partir d'un mode de tirage alterné. On présente au réseau le premier échantillon de la première classe, suivi d'un échantillon de la seconde classe et enfin d'un échantillon de la troisième classe. On réitère l'opération jusqu'à épuisement de la base d'apprentissage.

Pour les tests 1, 2 et 3 avec, respectivement, un t_{max} de 90, 120 et 150, on remarque une distribution relativement bonne à t_{max} = 150. Dépassé ce seuil, on constate que le réseau sur-apprend et délivre une mauvaise répartition des neuf neurones recherchés. Pour la seconde série de tests, on obtient une même représentativité que celle de la première série, mais avec des valeurs de t_{max} inférieures à celles des tests 1, 2 et 3 (figures 5 et 6). Ce résultat a conduit à choisir le mode de tirage alterné pour la validation du réseau GNG.

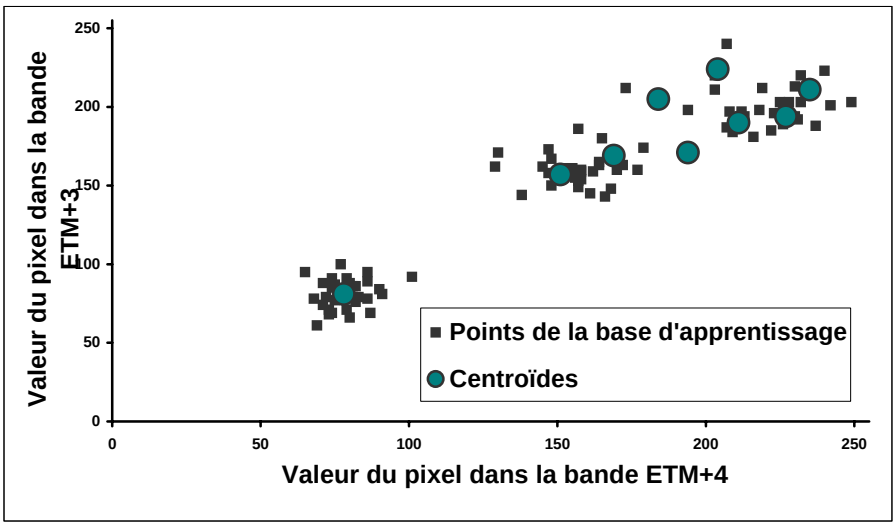


Figure 5 : Centroïdes obtenus avec t_{max} = 120 pour un mode de tirage séquentiel. *Kernels obtained with* t_{max} *= 120, sequential pulling.*

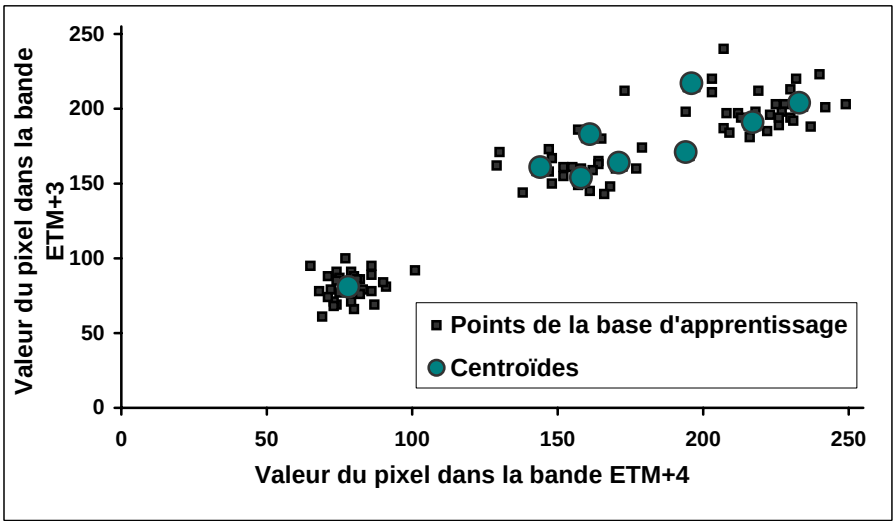


Figure 6 : Centroïdes obtenus avec t_{max} = 90 pour un mode de tirage alterné. *Kernels obtained with* t_{max} *= 90, alternate pulling.*

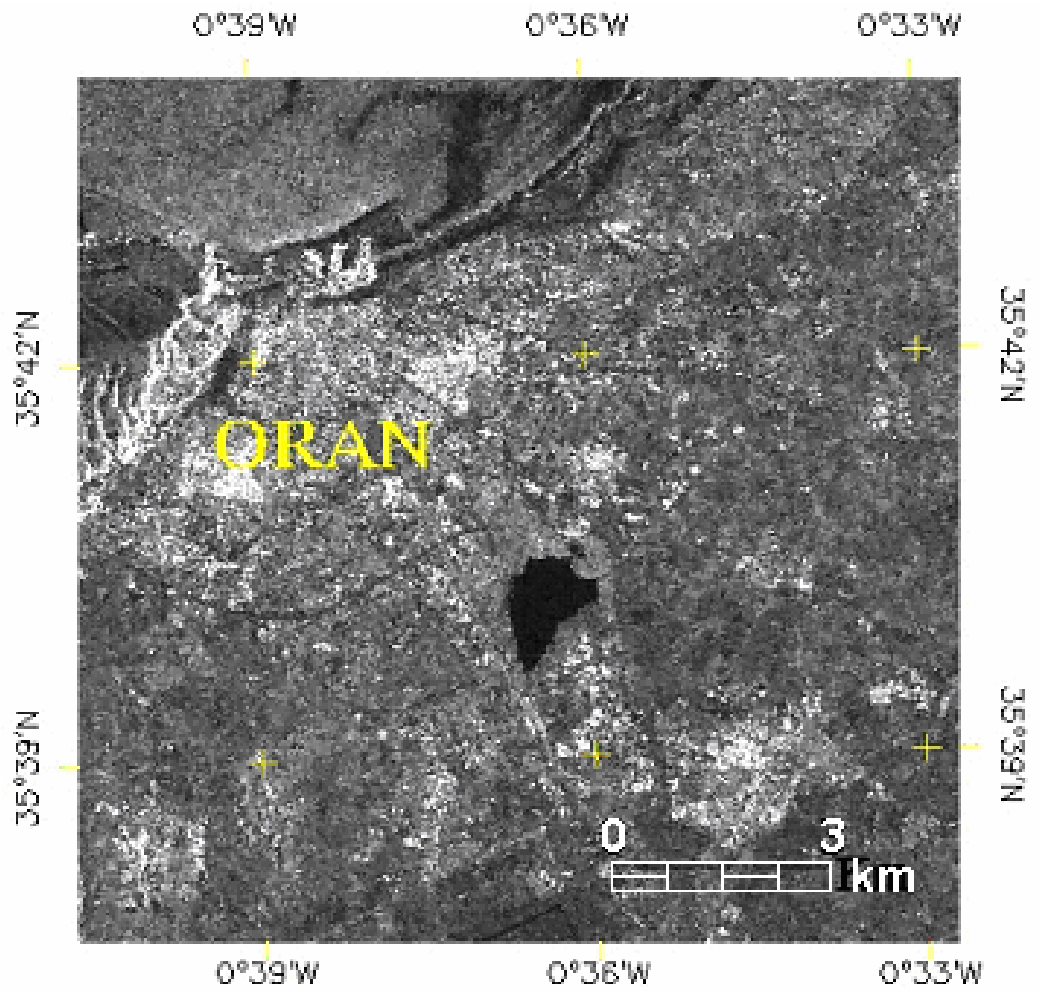


Figure 7 : Image radar. *Radar image.*

3.4. Approche préconisée

Dans un premier temps et afin de comparer l'algorithme GNG avec un algorithme classique, notre choix s'est porté sur l'algorithme ISODATA (*Iterative Self-Organizing Data Analysis Technics*) qui a le même type d'apprentissage. Ce dernier est auto-organisateur et itératif parce qu'il effectue plusieurs passes à travers l'ensemble de données, jusqu'à ce que les résultats attendus soient obtenus (Sing-Tze, 1992). Les paramètres à intégrer par l'analyste sont le nombre de classes et le nombre d'itérations. Cette comparaison est réalisée sur des fenêtres de 400 x 400 pixels.

Dans un second temps et pour ce qui est de l'approche préconisée, les phases suivantes seront exécutées :

- classification des données purement spectrales à l'aide de l'algorithme GNG ;

- détection des confusions sur l'image des classes ;

- extraction des classes présentant des confusions ; l'extraction est effectuée en utilisant un masque sur les classes jugées bien classifiées ;

- identification des données exogènes pouvant lever les confusions constatées ;

- intégration des données multisources pour améliorer l'image des classes ; l'intégration peut être effectuée de deux façons : reprise de la classification globale avec intégration des données exogènes ou reprise de la classification seulement sur les classes présentant des confusions ; pour ce qui est de la première solution, une classification globale par intégration des données exogènes peut corriger les confusions existantes, mais elle peut aussi générer de nouvelles confusions parmi les classes bien classifiées ; en plus, elle est coûteuse en temps de calcul ; cette solution est donc à éviter ; la seconde solution apparaît mieux adaptée à cette situation ;

- reconstitution de l'image des classes finales en superposant les classes re-classifiées avec celles qui ont été masquées.

Les valeurs des paramètres du réseau GNG finalement retenues sont : $t_{\max} = 90$, $a_{\max} = 30$, $\tau = 100$, $\eta_g = 0{,}05$, $\eta_v = 0{,}0006$, $Voisinage = 2$, $\alpha = 0{,}6$.

3.5. Description des données auxiliaires

En plus des données optiques, le choix s'est porté sur les données exogènes radar et de pente. Les données radar et, plus précisément, celles de la bande d'amplitude ont été utilisées pour différencier les types de sols sachant qu'elle est sensible à la rugosité (Girard et Girard, 2004). Les données de pente extraites du MNA permettent de distinguer entre les thèmes présentant des réponses spectrales similaires, notamment entre les thèmes « Mer » et « Maquis », lorsque ce dernier est situé dans une zone d'ombre.

3.5.1. Image radar

Sur la figure 7, on présente une portion des données d'amplitude extraite de l'image RSO d'ERS-2 acquise le 15 avril 2001 et présentée par une fenêtre de 3 000 x 1 680 pixels. Cette image acquise en mode de polarisation VV avec un angle d'incidence de 23° et une résolution de 12,5 x 12,5 m a été traitée dans le cadre de cette étude. Elle est préalablement filtrée dans le but de réduire le chatoiement (*speckle*) inhérent à l'image radar, qui est provoqué par le phénomène d'interférences aléatoires entre les ondes cohérentes émises par le radar au niveau de la surface de réflexion (Hein, 2004). Le filtre utilisé est le filtre adaptif de Frost avec une fenêtre de taille 3 x 3 et une seule itération. Ce choix est justifié par un meilleur résultat que celui qui est obtenu à l'aide des autres filtres (Iftene et Mahi, 2005). Les données sont ensuite placées dans le même référentiel géométrique que celui des données optiques. La correction a été effectuée en appliquant la méthode polynomiale de degré 1 sur un ensemble de 12 points amers. L'erreur moyenne résiduelle obtenue est égale à 1,79 pixels, soit une erreur inférieure à 2 pixels, ce qui correspond à 25 m.

3.5.2. Image des pentes

Sur la figure 8, on présente l'image des pentes extraites du modèle numérique d'altitude de la région d'étude. Elle est ensuite rééchantillonnée à 30 m et corrigée géométriquement par rapport aux autres données.

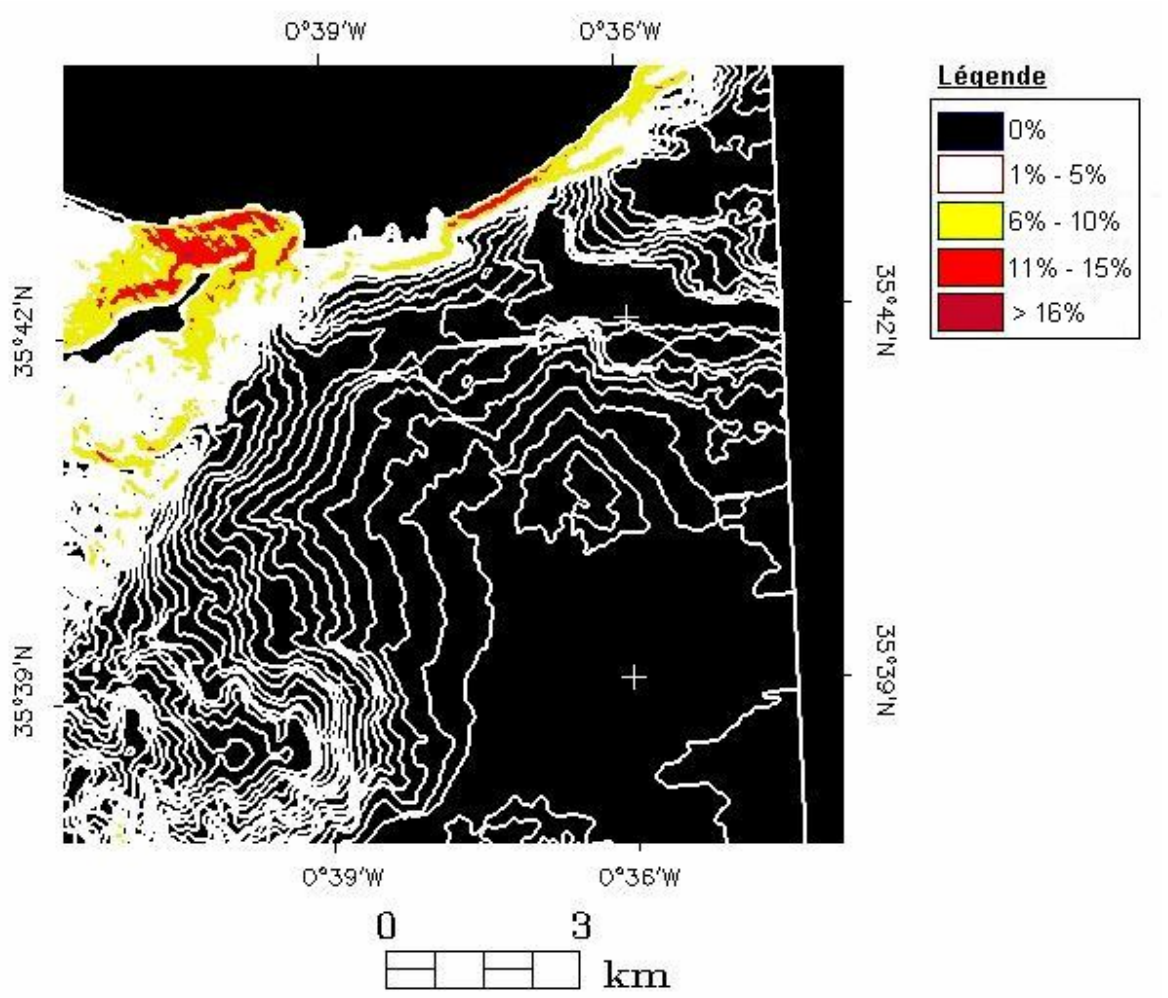


Figure 8 : Image des pentes. *Slope image.*

4. APPLICATION

Sur la figure 10, on présente le résultat d'une classification faite à l'aide de l'algorithme ISODATA et appliqué à une portion du site d'étude (figure 9). Ce test a été réalisé en fixant le nombre de classes à 6, ce nombre étant égal au nombre de thèmes existant sur cette portion du site d'étude. Le nombre d'itérations est fixé à 6 car, dépassé ce nombre, l'algorithme délivre le même résultat.

Sur la figure 11, on présente le résultat d'une classification faite à l'aide de l'algorithme GNG avec le même nombre de classes et le même nombre d'itérations que pour l'algorithme ISODATA. À partir des matrices de confusion calculées sur des échantillons de validation (tableaux 1 et 2), on constate que le résultat du nouveau classifieur est meilleur que celui qui est obtenu à l'aide de l'algorithme ISODATA. Néanmoins, on constate de la confusion, plus particulièrement entre les classes « Mer » et « Maquis » (figure 12), Cette confusion est due à l'effet d'ombre ainsi qu'à la similitude des réponses spectrales entre les classes « Zone bâtie » et « Jachères ».

Sur la figure 13, on présente le résultat de l'intégration des données radar et des pentes. On doit mentionner que les données radar a été intégrées afin d'éliminer la confusion entre la classe « Zone bâtie » et la classe « Jachères ». Les données de pente ont permis de discerner la classe « Mer » de la classe « Maquis ». À la suite de l'intégration de ces données auxiliaires, on remarque que la classification a été améliorée, comme en témoigne la matrice de confusion obtenue à partir des échantillons de validation (tableau 3).

Le logiciel ENVI (*Environment for Visualizing Images*) a été utilisé pour l'extraction du fichier des pentes, pour les corrections géométriques entre les différentes données et pour la classification non dirigée à l'aide l'algorithme ISODATA. L'algorithme GNG a été appliqué avec le langage de programmation Builder C++. Enfin, tous les traitements inhérents à ce travail ont été réalisés sur un PC Pentium III 866 Mhz.

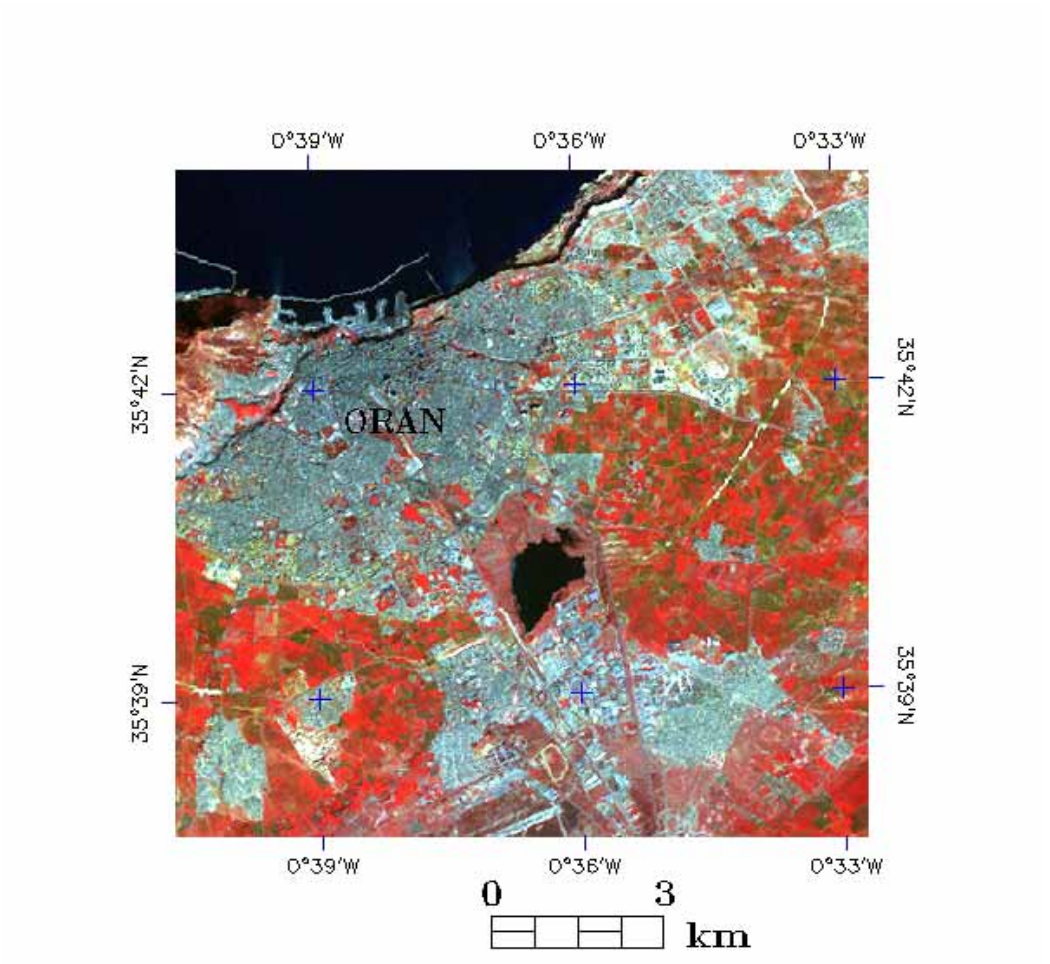


Figure 9 : Composition colorée des bandes ETM$^+$ 4, 3,1 d'une portion du site d'étude. *Colour composition of the ETM+ 4, 3, 1 bands of part of the study area.*

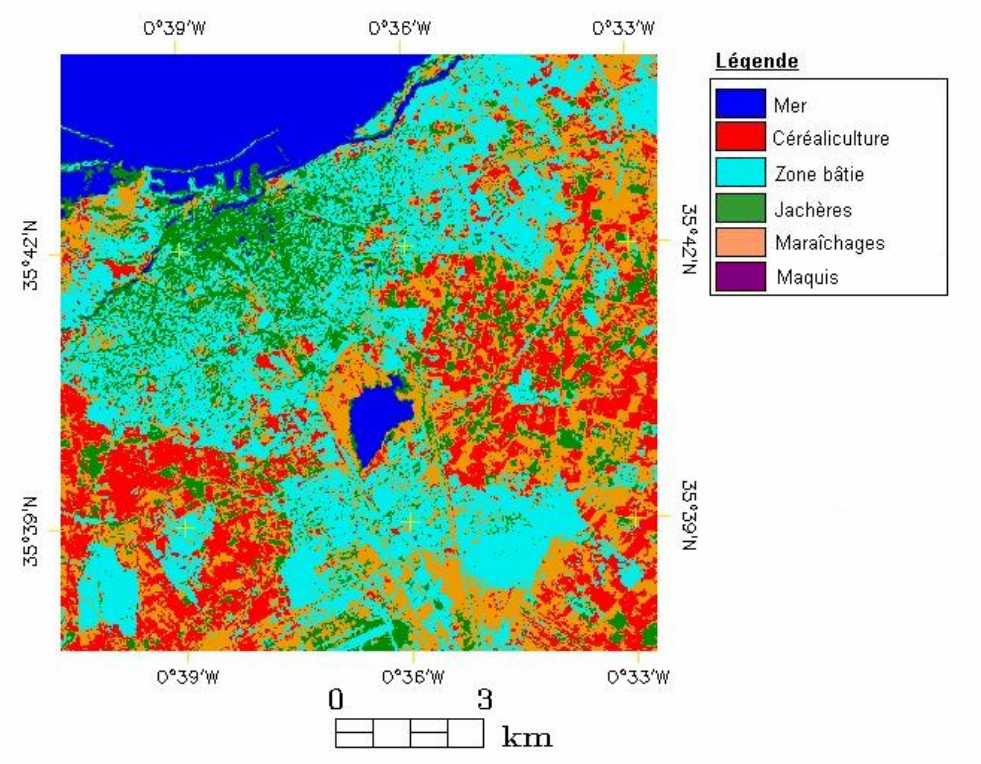


Figure 10 : Image des classes obtenue à l'aide de l'algorithme ISODATA. *ISODATA classification image.*

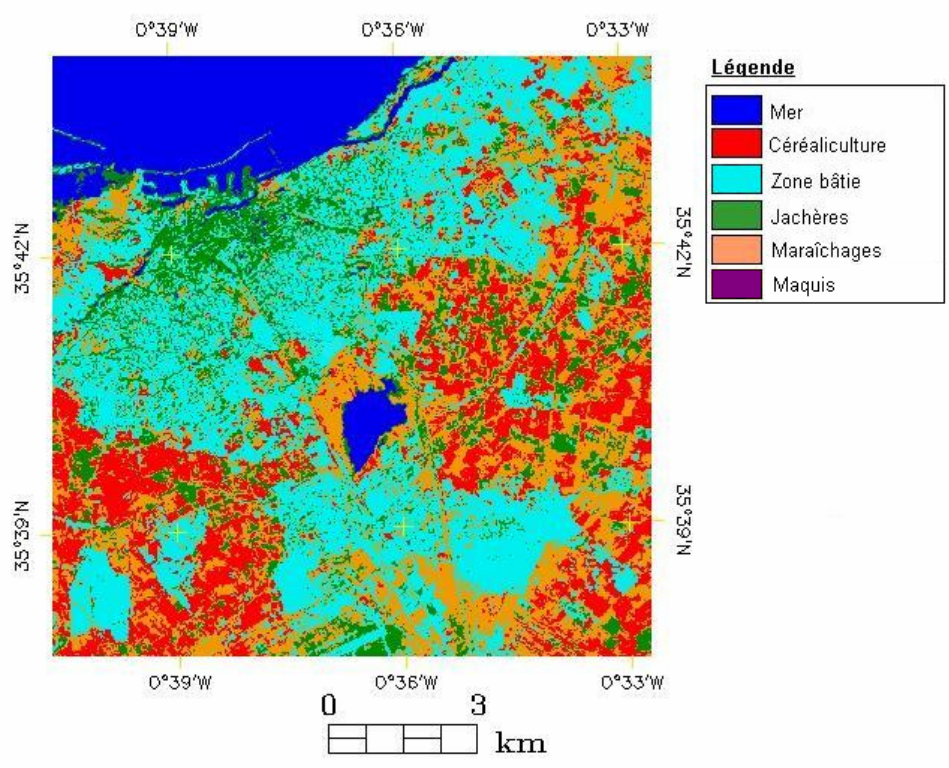


Figure 11 : Image des classes obtenue à l'aide de l'algorithme GNG. *GNG classification image.*

Tableau 1 : Matrice de confusion relative à la figure 10. *Confusion matrix of figure 10.*

		Classification par ISODATA sur les données optiques						
		Mer	**Zone bâtie**	**Céréalicultures**	**Jachères**	**Maraîchages**	**Maquis**	**TOTAL**
Échantillons de validation	**Mer**	100	0	0	0	0	0	**100**
	Zone bâtie	0,41	46,80	1,34	51,45	0	0	**100**
	Céréalicultures	0	0	100	0	0	0	**100**
	Jachères	0	8,05	0	85,55	6,40	0	**100**
	Maraîchages	0	0	8,22	9,49	82,29	0	**100**
	Maquis	80,92	0	0	5,23	13,85	0	**100**
	Précision totale de la classification en (%)							**69,10**

Tableau 2 : Matrice de confusion relative à la figure 11. *Confusion matrix of figure 11.*

		Classification par GNG sur les données optiques						
		Mer	**Zone bâtie**	**Céréalicultures**	**Jachères**	**Maraîchages**	**Maquis**	**TOTAL**
Échantillons de validation	**Mer**	100	0	0	0	0	0	**100**
	Zone bâtie	0,32	65,89	1,05	32,74	0	0	**100**
	Céréalicultures	0	0	100	0	0	0	**100**
	Jachères	0	6,20	0	89,85	3,95	0	**100**
	Maraîchages	0	0	9,11	3,26	87,63	0	**100**
	Maquis	77,06	0	0	7,56	15,38	0	**100**
	Précision totale de la classification en (%)							**73,89**

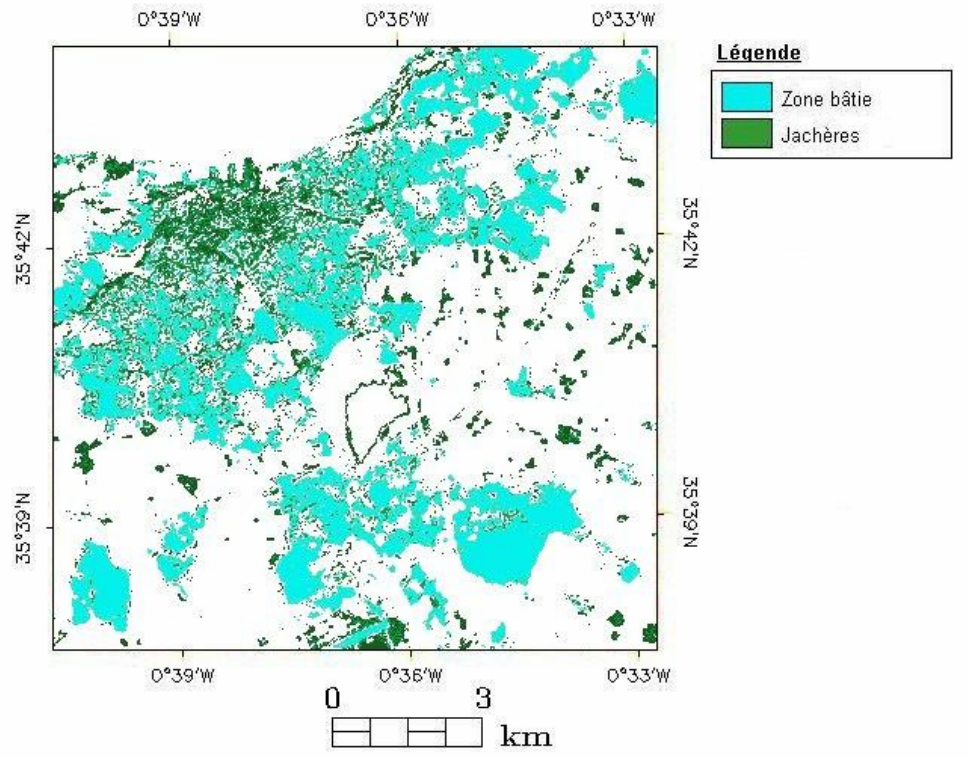


Figure 12 : Image de la confusion entre les thèmes Urbain et Jachères. *Confusion image between the urban and fallow themes.*

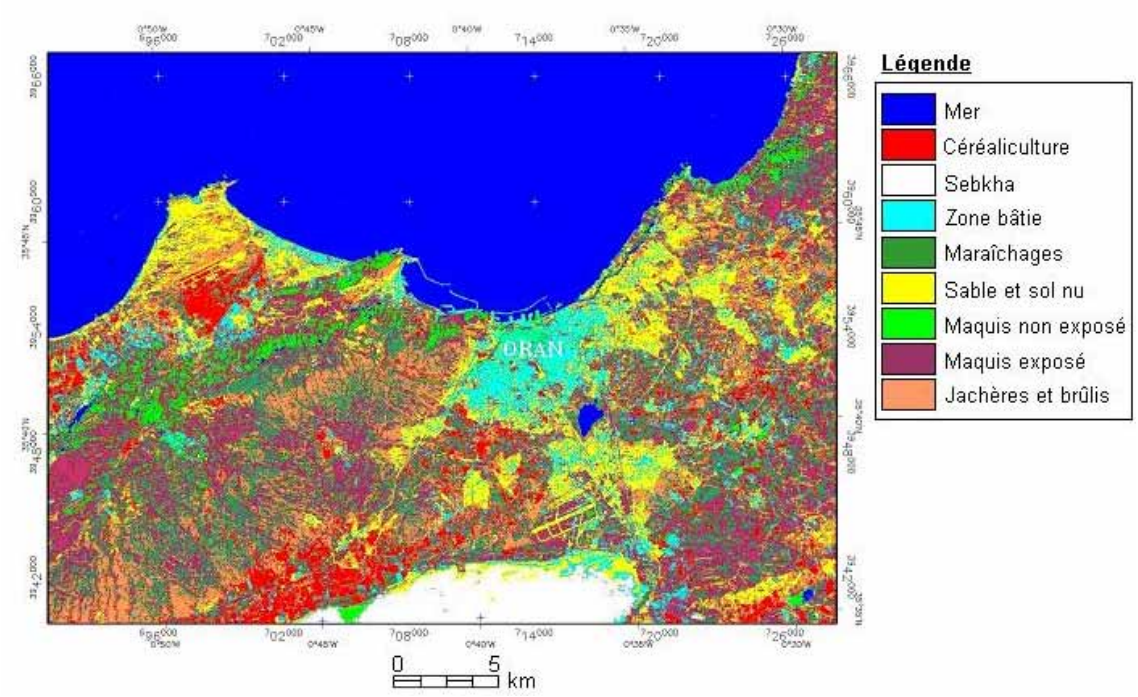


Figure 13 : Carte d'occupation des terres obtenue après l'intégration des données radar et de pente. *Land cover map obtained after radar and slope data integration.*

Tableau 3 : Matrice de confusion relative à la classification des données multisources à l'aide de l'algorithme GNG. *Confusion matrix of multisource data classification using the GNG algorithm.*

		Classification par GNG sur les données optiques, pente et radar									
		Mer	**Céréalicultures**	**Maquis non exposé**	**Maquis exposé**	**Jachères et brûlis**	**Maraîchages**	**Sebkha**	**Zone bâtie**	**Sable et sol nu**	**TOTAL**
Échantillons de validation	**Mer**	100	0	0	0	0	0	0	0	0	**100**
	Céréalicultures	0	100	0	0	0	0	0	0	0	**100**
	Maquis non exposé	0	0	85,19	0	0	14,81	0	0	0	**100**
	Maquis exposé	0	0	0	87,67	12,23	0	0	0	0	**100**
	Jachères et brûlis	0	0	0	0	96,88	0	0	0	3,12	**100**
	Maraîchages	0	6,52	0	2,18	13,04	78,26	0	0	0	**100**
	Sebkha	0	0	0	0	0	0	100	0	0	**100**
	Zone bâtie	0	0	0	0	0	0	4,20	91,67	0	**100**
	Sable et sol nu	0	0	0	0	0	0	0	17,64	82,36	**100**
	Précision totale de la classification (%)										**91,34**

5. CONCLUSION

L'utilisation conjointe des réseaux de neurones et des données multisources, à savoir les données radar et les produits dérivés du modèle numérique d'altitude, a permis de remédier à la confusion constatée sur la classification utilisant exclusivement l'information spectrale. Aussi, il paraît clair que la nouvelle approche à l'aide de l'algorithme GNG utilisée ici a montré toute son efficacité et sa robustesse quant à l'intégration et à la classification de données provenant de sources différentes par rapport aux algorithmes classiques à même vocation. Néanmoins, le temps de convergence reste à optimiser.

En perspective, il est envisagé d'utiliser une version dirigée de l'algorithme GNG (Holmstöm, 2002), appelé SGNG (*Supervised Growing Neural Gas*), dont le principe est d'intégrer des échantillons reflétant la réalité de terrain puisqu'on travaillera dans un environnement dirigé et, par conséquent, les résultats devraient être plus précis.

Références

Besse, P. (2005) Data Mining - Modélisation statistique et apprentissage. Rapport pédagogique, Université Paul Sabatier, Toulouse, 103 p.

Girard, M.-C. et Girard, C.M. (2004) Traitement des données de télédétection. Dunod, Paris, 529 p.

Hein, A. (2004) Processing of SAR Data, Fundamental Signal Processing, Interferometry. Springer-Verlag, Berlin, 279 p.

Holmstöm, J. (2002) Growing Neural Gas, Experiments with GNG, GNG with Utility and Supervised GNG. Mémoire de maîtrise, Uppsala University, Uppsala, 38 p.

Iftene, T. et Mahi, H. (2005) Outils scientifiques d'analyses et de traitements : utilisation des connaissances expertes et des données multisources pour la réalisation de la carte des changements de l'occupation du sol : cas de la région d'Oran. Seminar on the Use of Space Technology for Disaster Management, 22-26 mai 2005, Agence spatiale algérienne, Alger, 7 p.

Iftene, T., Mahi, H. et Isabaten, H. (2003) Approche de classification par réseaux de Kohonen pour établir des cartes d'occupation du sol de la région d'Oran. Télédétection, vol. 3, n° 5, p. 325-336.

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

Parizeau, M. (2006) Réseaux de neurones. Rapport pédagogique GIF-21140 et GIF64326, Université Laval, Québec, 116 p.

Sing-Tze, B. (1992) Pattern recognition and image preprocessing. Marcel Dekker, New York, 558 p.

Touzet, C. (1992) Les réseaux de neurones artificiels. Introduction au connexionisme ; cours, exercices et travaux pratiques. Laboratoire d'études et de recherche en informatique, Nîmes, 127 p.

Yin, H. and Allinson, N.M. (2001) Self-Organizing Mixture Networks for Probability Density Estimation. IEEE Transactions on Neural Networks, vol. 12, n° 2, p. 405-411.

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