

# Réduction du nombre de canaux des images multispectrales par approche connexionniste

---

## An improved neural network technique for data dimensionality reduction in satellite imagery

par M. JANATI IDRISSE<sup>1</sup>, A. SBIHI<sup>1</sup>, R. TOUAHNI<sup>1</sup>, A. ROUKHE<sup>2</sup>, et A. AÏT FORA<sup>1</sup>

<sup>1</sup> Université Ibn Tofail, Faculté des Sciences, B.P. 14000, Kénitra, Maroc

<sup>2</sup> Université Moulay Ismail, Faculté des Sciences, B.P. 4010, Meknès, Maroc

e-mail : mjanati@caramail.com

### *résumé et mots clés*

Ce papier présente une nouvelle technique de réduction du nombre de canaux spectraux pour aider à la classification des images multispectrales en mode d'occupation du sol. Cette technique, basée sur des réseaux de neurones multicouches, propose une règle d'apprentissage de ces réseaux qui adapte le gradient conjugué à la méthode de rétropropagation ; permettant ainsi une convergence rapide au réseau. Les résultats de classification sont évalués sur une fenêtre d'image Landsat-TM de 512\*512 pixels, relative à la région de Kénitra (Maroc), et comparés à ceux obtenus par les méthodes classiques.

Projection non linéaire, Réseaux de neurones, Images multispectrales, Gradient conjugué.

### *abstract and key words*

This paper presents an application of back-propagation neural network based mapping scheme of multispectral data images. The approach exploits the ability of neural networks for non-linear projection of multidimensional data, and their advantages over traditional methods. An updating rule for this network, based on the Conjugate Gradient Algorithm is used. The main advantage of this algorithm is the speedup of the convergence rate. Performance evaluation using a Landsat image of Kénitra region (Morocco) is carried out. Classification results of the proposed algorithm outperform those obtained using conventional methods

Non-linear projection, Neural networks, Remote sensing imagery, Conjugate gradient.

## 1. introduction

Actuellement, la télédétection dispose d'une panoplie informatique de matériels et de logiciels de plus en plus performante qui permet des traitements plus poussés. Ces traitements se résument en des opérations d'extraction et de distinction de l'information. La discrimination des informations et leur organisation nécessitent l'emploi d'une méthode adéquate permettant de distinguer l'ensemble des pixels correspondant à une même catégorie de paysage selon l'application envisagée : discrimination des cultures, suivi du processus de déforestation, cartographie de la végétation... etc.

La classification multispectrale se présente comme une étape indispensable pour ce type de traitements ; son objectif est de regrouper les différents éléments (pixels) qui constituent l'image en thèmes correspondant à la couverture ou à la vérité du terrain. Cette discrimination des différents thèmes composant une image multispectrale est faite à partir des informations spectrales apportées par les canaux de l'image. Ces derniers sont en général corrélés deux à deux (similarité visuelle et spectrale), ce qui constitue une redondance d'informations. L'utilisation de tous les canaux à la fois n'étant donc pas nécessaire, on ne choisit souvent que les plus pertinents d'entre eux. Ce choix se fait en général par des techniques de compression des données ou de réduction de leur dimension. En général, on ne retient que trois canaux étant donné que les systèmes d'affichage des unités de traitement d'images permettent seulement l'affichage de trois canaux (*via* les trois couleurs primaires).

Dans ce contexte, plusieurs travaux ont eu recours à l'analyse en composantes principales, ACP, [Hill 89, Def 90, Man 91, Bon 92]. Cette technique, souvent utilisée comme une opération préalable à une classification, permet de compresser dans un nombre réduit de canaux les informations contenues dans tous les canaux, tout en préservant la précision d'extraction d'informations [Mat 93]. Toutefois, ce type de transformation, qui consiste à caractériser tout point de l'image par une combinaison linéaire des canaux d'origine, ne permet pas, pour des distributions non linéaires, de revenir aux comportements spectraux et donc aux données d'origine [Gir 89]. Dans ce cas, il est nécessaire de faire appel à des discriminateurs plus complexes de type non linéaire.

En effet, des recherches dans le domaine des réseaux de neurones ont permis de développer des techniques de réduction de la dimension de l'espace de représentation des données multidimensionnelles [Jai 92, Ker 92]. Le principal avantage des réseaux de neurones réside dans leur faculté à élaborer une transformation analytique faisant appel à une fonction linéaire, ou non linéaire, entre l'espace d'observations et l'espace de projection, tout en préservant en projection, autant que possible, la structure locale des observations multidimensionnelles. Des travaux, [Dao 94, Ham 95], ont montré par une étude comparative

l'efficacité des traitements par des réseaux de neurones multicouches non linéaires par rapport aux traitements par l'ACP. En effet, l'espace de projection obtenu par l'ACP (une transformation linéaire) étant celui des axes dans lesquelles les données présentent les plus fortes dispersions ; il ne révèle, pour des distributions non linéaires, ni la structure locale des données, ni la séparabilité des classes. Par contre, la projection obtenue par un réseau de neurones multicouches, (réalisant une transformation non linéaire) se fait à travers des courbes curvilignes, ce qui permet d'extraire plus d'informations et mieux représenter la structure des données de départ [Kar 94].

Le travail proposé dans ce papier a pour principal objectif d'évaluer l'apport des réseaux de neurones dans le traitement des images multispectrales. Il consiste en la réduction du nombre de canaux spectraux d'une image Thematic Mapper par un Réseau de Neurones Multicouches (RNM) non linéaires. Les règles d'apprentissage de ce dernier adaptent le gradient conjugué à la méthode de rétropropagation pour assurer ainsi une convergence rapide au réseau.

La section 2 décrit l'architecture et la procédure d'apprentissage du réseau de neurone multicouche conçu pour la projection des données multidimensionnelles dans un espace de dimension réduite à deux ou trois. Les règles d'apprentissage sont basées sur l'algorithme du gradient conjugué permettant ainsi une optimisation de la procédure d'apprentissage qui utilise la méthode de rétropropagation du gradient classique. La section 3, présente l'application de l'approche proposée à la réduction du nombre des canaux d'une image Landsat-TM de la région de Kénitra (Maroc). La classification en mode d'occupation du sol est faite sur la base des canaux résultants de la méthode connexionniste proposée, sur la base des canaux résultants de l'ACP et enfin, sur la base des trois canaux brutes jugés les plus pertinents. Une comparaison des résultats obtenus permet une évaluation de l'approche proposée.

## 2. projection des données multidimensionnelles par réseaux de neurones multicouches

L'essor qu'ont connu les réseaux de neurones a fait apparaître une grande variété de types de réseaux qui, tout en partageant des propriétés essentielles, se distinguent entre eux par les applications visées, par leur topologie et par le type d'apprentissage utilisé pour ajuster les paramètres. Plusieurs réseaux ont été exploités pour la projection des données multidimensionnelles dans un espace de dimension réduite. Nous nous sommes particulièrement intéressés au réseau multicouches non linéaire [Lec 87, Rum 86].

## 2.1. architecture du réseau multicouches

Etant conçu pour s'appliquer dans un contexte non supervisé, ce réseau est souvent appelé réseau auto-associatif. Il résulte en fait de l'association de deux réseaux montés en cascade. Le premier est appelé : « réseau projecteur », le second : « réseau reconstruteur ». Ce type de réseau fournit à la fois la projection des données et la reconstruction de ces données à partir des projections. Le réseau ici utilisé est constitué de cinq couches (cf. figure 1) : une couche d'entrée, une couche de sortie et trois couches cachées. Les couches d'entrée et de sortie présentent le même nombre de neurones ( $N$ ) qui est celui de la dimension de l'espace de représentation des données ; le nombre de neurones ( $m$ ) dans la 2<sup>ème</sup> couche cachée représente la dimension de l'espace de projection. La 1<sup>ère</sup> et la 3<sup>ème</sup> couches cachées ont le même nombre de neurones ( $h$ ). Le choix de ce nombre étant délicat, il peut être guidé par la théorie de l'information en vue de minimiser l'architecture du réseau. L'une des méthodes permettant ce choix consiste à utiliser des fonctions exprimant un compromis entre le nombre total des poids du réseau et le logarithme népérien de l'erreur moyenne de reconstitution des observations. Parmi ces fonctions on peut utiliser celle proposée par Akaike [Aka 74] telle que :

$$AIC(h) = \ln(\bar{E}) + \frac{2N_p}{QN} \quad (1)$$

avec  $\bar{E}$  la fonction erreur totale,  $Q$  le nombre total des observations et  $N_p$  le nombre total des poids du réseau exprimé en fonction de  $h$  par :

$$N_p = [(N + 1)h + (h + 1)2 + (2 + 1)h + (h + 1)N] \quad (2)$$

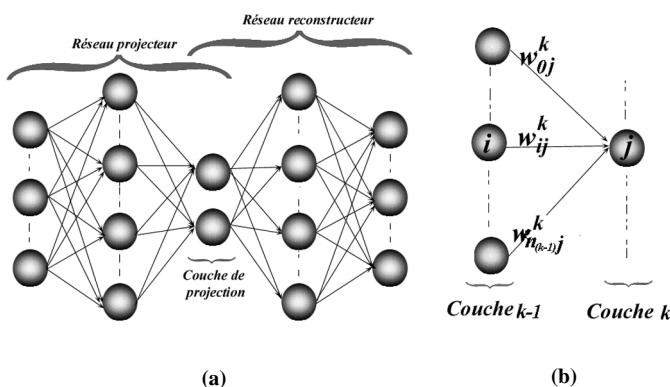


Figure 1. – (a) Réseau multicouche autoassociateur à apprentissage non supervisé, (b) liaison du  $i^{\text{ème}}$  neurone de la couche  $k - 1$  vers le  $j^{\text{ème}}$  neurone de la couche  $k$ .

Selon les références [Bet 95, Ham95], l'optimisation de l'architecture du réseau est effectuée en faisant varier le nombre  $h$  des neurones cachés et en calculant le critère  $AIC$  pour chaque nombre. Le nombre optimum est celui qui correspond au minimum de ce critère.

## 2.2. apprentissage par rétropropagation du gradient conjugué

L'apprentissage du réseau s'effectue à partir d'un échantillon de  $Q$  observations  $\{X_1, X_2, \dots, X_q, \dots, X_Q\}$  de dimension  $N$ .

A la présentation d'une observation  $X_q = [x_{q,1}, x_{q,2}, \dots, x_{q,N}]^T$  à l'entrée du réseau (couche 0), la sortie de chaque neurone  $j$  de la  $k^{\text{ème}}$  couche est calculée à partir des sorties de tous les neurones de la  $(k - 1)^{\text{ème}}$  couche par l'équation suivante :

$$y_{q,j}^k = f \left( \sum_{i=0}^{n_{k-1}} w_{ij}^k y_{q,i}^{k-1} \right) \quad k = 1, 2, 3, 4 \quad (3)$$

où  $w_{ij}^k$  représente le poids synaptique associé à la connexion entre le neurone  $i$  de la  $(k - 1)^{\text{ème}}$  couche et le neurone  $j$  de la couche  $k$ ;  $f(\cdot)$  est la fonction d'activation des neurones, exprimée ici par :  $f(u) = \frac{1 - \exp(-u)}{1 + \exp(-u)}$

Soit  $Y_q^k = [y_{q,1}^k, y_{q,2}^k, \dots, y_{q,j}^k, \dots, y_{q,n_k}^k]^T$  le vecteur sortie de la couche  $k$ . Ce vecteur est tel que :

$$Y_q^k = f(W^T Y_q^{k-1}) \quad \text{avec } Y_q^0 = X_q \quad (4)$$

L'apprentissage, qui consiste en un entraînement du réseau pour modifier les poids des connexions, vise toujours à optimiser un certain critère dépendant des données à analyser. Comme le réseau étudié doit fournir en sortie une estimation de l'observation présentée à son entrée, cela revient à minimiser la fonction erreur entre la sortie désirée, qui n'est autre que l'entrée du réseau ( $S_q = X_q = Y_q^0$ ), et la sortie estimée par le réseau :  $Y_q^4$ . Cette fonction peut être définie comme étant l'erreur quadratique  $E(W)$  telle que :

$$E(W) = [S_q - Y_q^4]^2 = [S_q - f(W^4 Y_q^0)]^2 \quad (5)$$

Les procédures d'apprentissage consistent alors à trouver une configuration des poids des connexions qui minimise la fonction erreur. Ainsi, les règles d'apprentissage sont définies d'une part, par la forme de la fonction erreur, et d'autre part, par la technique de minimisation employée. La procédure d'apprentissage la plus utilisée est la technique de rétropropagation, proposée par [Lec 86] et [Rum 86]. Bishop présente plusieurs méthodes d'optimisation de cette fonction dans [Bis 95], notamment celle basée sur les Algorithmes du Gradient Conjugué (AGC). C'est à cette dernière méthode que nous nous sommes intéressés dans ce travail.

Le gradient conjugué a été introduit par Hestenes et Stiefel en 1952 [Hes 52] pour la minimisation des fonctionnelles quadratiques ; c'est un algorithme intermédiaire entre l'algorithme du gradient classique et l'algorithme de Newton [Dav 73]. C'est en fait une méthode de descente suivant des directions bien déterminées qui sont calculées à partir du gradient et des directions précédentes.

Toutefois, pour utiliser l'AGC et l'adapter pour l'apprentissage du réseau adopté dans notre étude, il nous est nécessaire de transformer la fonction erreur pour l'écrire sous une forme quadratique. Pour cela, nous proposons d'utiliser le développement de Taylor de la fonction  $f$  autour de zéro. Cette approximation nous permet d'écrire l'équation (5) sous la forme suivante :

$$E(W) = \frac{1}{2}(W^T R W) - W^T P + Cte \quad (6)$$

avec, 
$$R = \left( \begin{array}{cc} Y_q^3 & Y_q^{3T} \\ Y_q^{3T} & Y_q^3 \end{array} \right) \text{ et } P = (Y_q^3 S_q)$$

L'équation (6) prend en effet, la forme d'une fonctionnelle quadratique avec sa matrice  $R$  symétrique définie positive. Elle admet donc un minimum global et unique déterminé par :

$$\nabla(E(W)) = RW - P = 0 \quad (6)$$

Les règles d'apprentissage proposées se résument aux trois étapes suivantes :

*1<sup>ère</sup> étape :*

- Initialiser les poids  $W_0$  du réseau de manière aléatoire à des valeurs voisines de zéro ;
- Calculer le vecteur gradient  $r_0 = \nabla(E(W_0))$  ;
- Initialiser la direction de correction, le paramètre  $\beta_0 = 0$  et  $n = 1$  ;

*2<sup>ème</sup> étape :* à l'itération  $n$ , calculer la nouvelle direction de correction en utilisant les équations suivantes :

$$d_n = r_n + \beta_n d_{n-1} \text{ avec } \beta_n = \frac{\langle r_n, r_n \rangle}{\langle r_{n-1}, r_{n-1} \rangle}$$

*3<sup>ème</sup> étape :*

- Adapter les poids conformément à l'équation suivante :

$$W_{n+1} = W_n - \lambda_n d_n \text{ avec } \lambda_n = \frac{\langle r_n, r_n \rangle}{\langle d_n, R d_n \rangle}$$

- Calculer le vecteur gradient à l'itération  $(n + 1)$  :

$$r_{n+1} = \nabla E(W_{n+1}) ;$$

Si le vecteur gradient  $\|r_{n+1}\|$  est très voisin de zéro, on arrête l'apprentissage ; sinon on reprend le processus à partir de l'étape 2. Dans la section suivante, nous décrivons l'application de cette approche connexionniste à la réduction du nombre de canaux d'une image satellitaire.

## 3. application à la réduction du nombre de canaux d'images satellitaires

### 3.1. introduction

La zone d'étude est une fenêtre de 512\*512 pixels, extraite de la scène Landsat-TM de la région de Kénitra prise en 1987. Le choix de cette zone est motivé par le fait que les sites et les paysages qu'elle recouvre n'ont pas beaucoup changé depuis la date de la prise de l'image jusqu'à nos jours. Ainsi, nous avons pu interpréter l'image et confronter nos résultats avec des vérités de terrain que nous avons relevées récemment pour l'application décrite dans ce papier.

Les données brutes du Thematic Mapper (TM) de Landsat sont constituées de sept canaux : le bleu (TM1), le vert (TM2), le rouge (TM3), le proche infrarouge (TM4) et le moyen infrarouge (TM5 et TM7) ; le canal thermique (TM6) a été exclu des traitements.

Etant donné que les canaux des images TM sont en général très corrélés deux à deux et que les systèmes d'affichage des unités de traitement d'images permettent seulement l'utilisation de trois canaux, le principal objectif de cette application est de réduire le nombre de canaux spectraux de l'image TM à trois.

En effet, l'approche connexionniste, décrite plus haut, appliquée pour le traitement de l'image (TM) avec trois neurones sur la couche de projection du réseau, permettrait de réduire le nombre de canaux spectraux de l'image à trois tout en préservant en projection, autant que possible, la structure locale des données multispectrales. Les nouveaux canaux résultants de cette procédure devraient offrir un meilleur taux d'information et permettre ainsi de générer une composition colorée de l'image.

### 3.2. traitement des données

Les fichiers de l'image représentent chaque pixel par autant de paramètres que de nombre de canaux spectraux. Ce nombre étant égal à six, chaque pixel est donc considéré comme une observation à six dimensions. L'architecture du réseau utilisé pour le traitement de l'image (cf. figure1) est donc de 6-9-3-9-6 (6 neurones dans les couches d'entrée et de sortie et trois neurones dans la couche de projection). Le nombre de neurones de la 1<sup>ère</sup> et 3<sup>ème</sup> couches cachées est déterminé par le minimum du critère informationnel d'Akaike de façon à ajuster l'architecture du réseau à la structure des données (cf. § 2.1.). Dans notre cas, ce nombre a été fixé à 9. L'apprentissage du réseau s'effectue en présentant à chaque époque toutes les observations (les pixels de

l'image) à l'entrée du réseau d'une manière séquentielle. Autrement dit, chaque observation intervient dans la correction des poids des connexions. Au bout de deux époques, l'erreur atteint son minimum indiquant ainsi la fin de l'apprentissage. Le réseau ayant appris la structure des données, les poids des connexions sont fixés.

La suite du traitement utilise uniquement le réseau projecteur (6-9-3). Les observations portant l'information sur les six canaux sont présentées séquentiellement à l'entrée de ce réseau. A la sortie du réseau, les observations de dimension réduite à trois, se trouvent porteuses de l'information uniquement sur trois pseudo-canaux. Ces derniers résultent donc d'une transformation non linéaire des informations contenues dans les canaux brutes et constituent la nouvelle image composée, représentée par la figure 2a.

Pour évaluer l'apport de la projection par réseau de neurones, nous avons opté pour une comparaison des résultats de la classification obtenus sur la base de trois compositions colorées : celle

résultante de l'approche connexionniste (cf. figure 2a), celle réalisée à partir des trois premières composantes principales (cf. figure 3a) et celle réalisée à partir de trois canaux brutes (cf. figure 4a). Cette dernière est constituée par les canaux de l'image qui, selon une étude statistique menée par le système de traitement ERDAS, offrent le moins d'information redondante et les meilleures qualités discriminantes entre les différents thèmes.

Les traitements pour la classification des trois images ont été réalisés à l'aide du logiciel ERDAS au Centre de Télédétection au sein de la Direction de la Planification et des Affaires Economiques du Ministère de l'Agriculture et la Mise en valeur Agricole (Maroc). La procédure de classification adoptée pour traiter les trois images est de type dirigée, basée sur le maximum de vraisemblance. Cette méthode utilise, pour déterminer l'appartenance d'un pixel à une classe, des fonctions probabilistes qui prennent en considération, aussi bien la variance spectrale à l'intérieur de chaque classe que la covariance entre les différentes classes.




Figure 2a. – Composition colorée de la zone étudiée, réalisée à partir des trois canaux résultant de la projection par l'approche connexionniste.




Figure 3a. – Composition colorée de la zone étudiée, réalisée à partir des trois premières composantes principales.

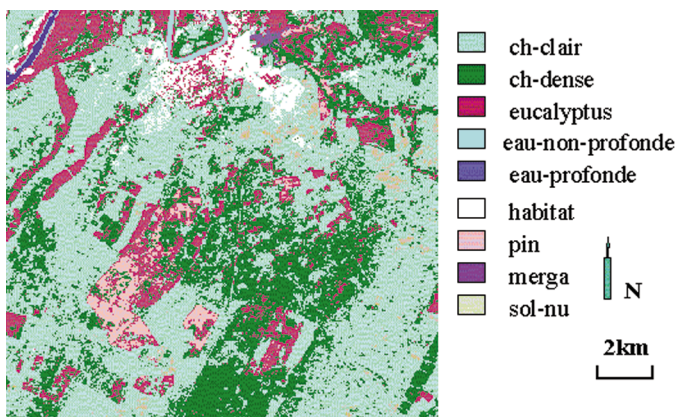


Figure 2b. – Classification sur la base de l'image composée obtenue par l'approche connexionniste.

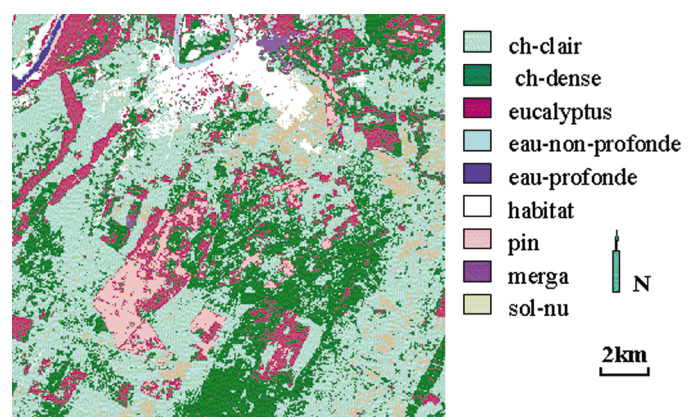


Figure 3b. – Classification sur la base de l'image composée obtenue par l'ACP.

La nomenclature des classes a été définie à partir des vérités de terrain. Des zones d'entraînement (échantillons représentatifs) ont été sélectionnés pour déterminer les caractéristiques spectrales de chaque groupe reconnu et identifié. Le choix de ces derniers est une étape cruciale dans le processus de la classification car le résultat en dépend. Les zones que nous avons choisies sont localisées facilement sur l'image, et distribuées de façon uniforme pour représenter tous les différents thèmes recherchés. Cette étape est jugée satisfaisante en utilisant des méthodes statistiques telle que la méthode des ellipses et celle de la matrice de contingence, qui permettent de vérifier que les zones choisies ne chevauchent pas entre elles. Enfin, on procède à la phase de généralisation sur l'ensemble du fichier en se basant sur les zones de contrôle où les résultats doivent être vérifiés. Ces zones sont différentes de celles utilisées pour l'entraînement.




Figure 4a. – Composition colorée de la zone étudiée, réalisée par les trois pertinents des canaux brutes.

### 3.3. résultats et discussions

Ce mode d'analyse a été appliqué aux trois images composées citées plus haut afin de pouvoir comparer les résultats de la classification. Une carte d'occupation des sols a été ainsi établie pour chacune des trois images, avec la mise en évidence de 9 thèmes cartographiques (cf. figures 2b, 3b et 4b).

L'évaluation de la précision de la classification est faite sur la base d'une comparaison de l'image avec la vérité de terrain. La méthode que nous avons utilisée se base sur la comparaison par pixels. Cette opération produit une matrice de confusion (ou matrice d'erreur) sur laquelle figurent les pixels correctement classifiés et ceux mal classifiés par catégorie.

L'analyse de cette matrice révèle, pour chaque classe, les erreurs de la classification. L'exactitude générale de la classification est obtenue par la moyenne des précisions relative aux différentes classes. Les matrices de confusions (cf. tableaux 1a, 2a et 3a) ont été calculées en se référant à 90 points de contrôle seulement. En fait, le choix restreint de 10 points de contrôle par classe, sachant que chaque point est le centre d'une matrice de 9\*9 pixels, était difficile à constituer étant donné que les parcelles étaient souvent de petite superficie.

Les matrices de confusions ont servi pour l'élaboration de trois tableaux synthétiques (cf. tableaux 1b, 2b et 3b) qui donnent, respectivement pour les trois images, la précision pour chaque classe, la précision globale et le coefficient d'agrément Kappa ( $K$ ). Ce coefficient est en effet souvent utilisé pour l'évaluation de la précision de la classification ; il représente la proportion d'agrément obtenue après avoir éliminé celle qui peut être due au hasard.

L'évaluation des résultats de traitement présentés montre que la précision totale de classification atteint 76 % pour le traitement de la composition par les trois pertinents des canaux brutes, 80 % pour le traitement de la composition par l'ACP, et 92 % pour le traitement de la composition par l'approche connexionniste. L'amélioration est significative car le pourcentage de l'information exacte, comparé au résultat obtenu par l'approche connexionniste, a augmenté de 12 % par rapport à l'image composée par les trois pertinents des canaux brutes. Par ailleurs, Le coefficient d'agrément Kappa passe respectivement de 0.73 à 0.77, puis à 0.91 entre l'image composée par les trois canaux brutes, la composition par l'ACP et la composition par l'approche connexionniste ; soit une amélioration dans la valeur de  $K$ , pour cette dernière, de 0.14 par rapport à celle obtenue par l'ACP et de 0.18 par rapport à celle obtenue par les trois canaux brutes. Ces résultats illustrent en effet l'avantage de l'utilisation des réseaux de neurones non linéaires pour l'amélioration de la classification des images multispectrales en mode d'occupation du sol.

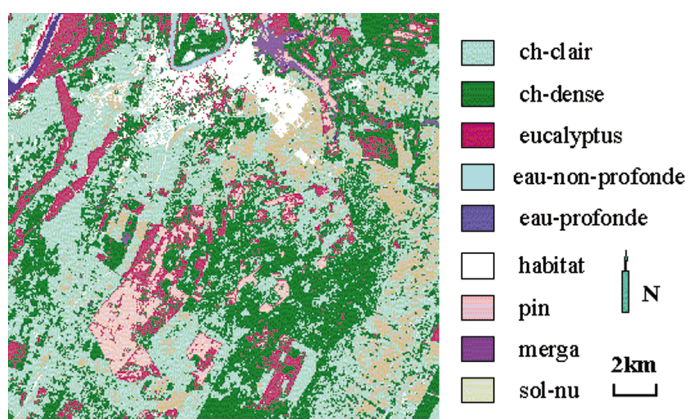


Figure 4b. – Classification sur la base de l'image composée obtenue par les trois pertinents des canaux brutes.

Tableau 1a. – Matrice de confusion établie par la classification de l'image composée à partir de l'approche connexionniste.

Classes observées sur le terrain												
classes obtenues par traitements numérique de l'image		1	2	3	4	5	6	7	8	9	total ligne	
	1 pin	10	0	0	0	1	0	0	0	0	0	11
	2 sol-nu	0	10	0	0	0	0	0	0	0	0	10
	3 ch-clair	0	0	10	0	0	0	0	0	0	0	10
	4 habitat	0	0	0	10	0	0	0	0	0	0	10
	5 ch-dense	0	0	0	0	9	0	2	0	0	0	11
	6 eau-prof	0	0	0	0	0	7	0	0	0	1	8
	7 eucalip	0	0	0	0	0	0	8	0	0	0	8
	8 eau-non-prof	0	0	0	0	0	1	0	10	0	0	11
	9 merga	0	0	0	0	0	2	0	0	0	9	11
total colonne	10	10	10	10	10	10	10	10	10	10	90	

Tableau 1b. – Pourcentages de précision de la classification de l'image composée à partir de l'approche connexionniste.

	nombre de points choisis	nombre de point classé	nombre correct	précision par classe
1 pin	10	11	10	90.9 %
2 sol-nu	10	10	10	100 %
3 ch-clair	10	10	10	100 %
4 habitat	10	10	10	100 %
5 ch-dense	10	11	9	81.8 %
6 eau-prof	10	8	7	87.5 %
7 eucalip	10	8	8	100 %
8 eau-non-prof	10	11	10	90.9 %
9 merga	10	11	9	81.8 %
total	90	90	83	92.22 %

 Coefficient d'agrément Kappa:  $K = 0,91$ 

Tableau 2a. – Matrice de confusion établie par la classification de l'image composée à partir de l'ACP.

Classes observées sur le terrain												
classes obtenues par traitements numérique de l'image		1	2	3	4	5	6	7	8	9	total ligne	
	1 pin	6	0	0	0	0	0	0	0	0	2	8
	2 sol-nu	0	8	2	0	0	0	0	0	0	0	10
	3 ch-clair	0	2	8	0	1	0	0	0	0	0	11
	4 habitat	0	0	0	10	0	0	0	0	0	0	10
	5 ch-dense	1	0	0	0	9	0	2	0	0	0	12
	6 eau-prof	0	0	0	0	0	6	0	0	0	1	7
	7 eucalip	3	0	0	0	0	0	8	0	0	0	11
	8 eau-non-prof	0	0	0	0	0	2	0	10	0	0	12
	9 merga	0	0	0	0	0	2	0	0	0	7	9
total colonne	10	10	10	10	10	10	10	10	10	10	90	

# Réduction du nombre de canaux des images multispectrales par approche connexionniste

Tableau 2b. – Pourcentages de précision de la classification de l'image composée à partir de l'ACP.

	nombre de points choisis	nombre de point classé	nombre correct	précision par classe
<b>1 pin</b>	10	8	6	75 %
<b>2 sol-nu</b>	10	10	8	80 %
<b>3 ch-clair</b>	10	11	8	72.7 %
<b>4 habitat</b>	10	10	10	100 %
<b>5 ch-dense</b>	10	12	9	75 %
<b>6 eau-prof</b>	10	7	6	85.7 %
<b>7 eucalip</b>	10	11	8	72.7 %
<b>8 eau-non-prof</b>	10	12	10	83.3 %
<b>9 merga</b>	10	9	7	77.7 %
<b>total</b>	90	90	72	<b>80 %</b>

Coefficient d'agrément Kappa:  $K = 0,77$

Tableau 3a. – Matrice de confusion établie par la classification de l'image composée à partir de trois canaux brutes.

Classes observées sur le terrain												
classes obtenues par traitements numérique de l'image		1	2	3	4	5	6	7	8	9	total ligne	
	<b>1 pin</b>	5	0	0	0	0	0	0	0	0	1	6
	<b>2 sol-nu</b>	0	7	2	0	0	0	0	0	0	0	9
	<b>3 ch-clair</b>	0	3	8	0	2	0	0	0	0	0	13
	<b>4 habitat</b>	0	0	0	10	0	0	0	0	0	0	10
	<b>5 ch-dense</b>	2	0	0	0	8	0	2	0	0	0	12
	<b>6 eau-prof</b>	0	0	0	0	0	5	0	0	0	1	6
	<b>7 eucalip</b>	3	0	0	0	0	0	8	0	0	0	11
	<b>8 eau-non-prof</b>	0	0	0	0	0	3	0	10	0	0	13
	<b>9 merga</b>	0	0	0	0	0	0	2	0	0	8	10
<b>total colonne</b>	10	10	10	10	10	10	10	10	10	10	90	

Tableau 3b. – Pourcentages de précision de la classification de l'image composée à partir de de trois canaux brutes.

	nombre de points choisis	nombre de point classé	nombre correct	précision par classe
<b>1 pin</b>	10	6	5	83.3 %
<b>2 sol-nu</b>	10	9	7	77.7 %
<b>3 ch-clair</b>	10	13	8	61.5 %
<b>4 habitat</b>	10	10	10	100 %
<b>5 ch-dense</b>	10	12	8	66.6 %
<b>6 eau-prof</b>	10	6	5	83.3 %
<b>7 eucalip</b>	10	11	8	72.7 %
<b>8 eau-non-prof</b>	10	13	10	76.9 %
<b>9 merga</b>	10	10	8	80 %
<b>total</b>	90	90	69	<b>76.66 %</b>

Coefficient d'agrément Kappa:  $K = 0,73$



## 4. conclusion

Le travail proposé dans ce papier concerne la réduction de la dimension des données multidimensionnelles par une approche connexionniste et son application pour le traitement des images multispectrales.

En effet, après une description de l'architecture du réseau adopté, nous avons opté pour une règle d'apprentissage par rétropropagation du gradient conjugué. Pour cela, nous avons montré comment transformer la fonction coût, utilisée par la méthode de descente du gradient classique, pour lui donner la forme d'une fonctionnelle quadratique avec une matrice symétrique définie positive. L'algorithme d'apprentissage proposé converge plus vite que celui basé sur la rétropropagation du gradient classique et de plus, garantit l'absence des minima locaux de la fonction coût.

L'application de cette approche connexionniste aux données d'une image multispectrale a permis de réduire le nombre de canaux d'origine sans perte significative d'information, et d'éliminer au maximum les corrélations entre ces canaux.

La comparaison, entre les résultats de la classification sur la base de trois compositions colorées obtenues respectivement par l'approche connexionniste, par l'ACP et par les trois pertinents des canaux brutes, montre que l'approche connexionniste proposée apporte une nette amélioration de la précision de la classification en mode d'occupation du sol.

Cette approche pourrait constituer une alternative pour l'analyse des images hyperspectrales. En effet, avec l'avènement de ce type d'images, on assiste au développement des méthodes de compression des données fournies par des capteurs couvrant une large fenêtre spectrale. L'image brute, composée de plusieurs centaines de milliers de Mbytes de données, pose ainsi les problèmes d'archivage et de transmission du satellite aux stations du sol [Abo 97, Can 98].

## BIBLIOGRAPHIE

- [Abo 97] G. P. Abousleman, M. W. Marcellin, B. R. Hunt, « Hyperspectral Image Compression Using Entropy-Constrained Predictive Trellis Coded Quantization », *IEEE Trans on Image Processing*, Vol. 6, n° 4, April 1997, pp. 566-573.
- [Aka 74] H. Akaike, « A new Look at the Statistical Model Identification », *IEEE Trans. on Automatic Control*, Vol. IV, 1974, pp. 716-722.
- [Bet 95] M. Betrouni, S. Delsert et D. Hamad, « Interactive Pattern Classification by Means of Artificial Neural Networks », *IEEE*, International Conference on System Man and Cybernetics (SMC), Vancouver, British Columbia, Canada, October, 1995, Vol. IV, pp. 3275-3279.
- [Bis 95] C. M. Bishop, « *Neural Networks for Pattern Recognition* », Clarendon Press, Oxford, 1995.
- [Bon 92] F. Bonn et G. Rochon, « *Précis de télédétection : Principes et méthodes* », Press de l'université de Québec. AUPELF, 1992, 512 pages.
- [Can 98] G. R. Canta, G. Poggi, « Kronecker-Product Gain-Shape Vector Quantization for Multispectral Image Coding », *IEEE Trans on Image Processing*, Vol. 7, n° 5, May 1998, pp. 668-678.
- [Dao 94] M. Daoudi, D. Hamad et J.G. Postaire, « A new Interactive Patter Classification Approach using five-layer Neural Networks and Mathematical Morphology », *EUFIT 94, Aachen, Germany*, September 1994.
- [Dav 73] David G. Luenberger, « *Introduction to Linear and Non Linear Programming* », Stanford University, 1973
- [Def 90] P. Defourny, « Méthodes d'évaluation quantitative de la végétation ligneuse en région Soudano-Sahélienne à partir de données Landsat TM (Burkina Faso) », *Actualité Scientifique, Télédétection et sécheresse*, Ed. AUPELF-UREF, Paris, France, 1990, pp.63-74.
- [Gir 89] M.C. Girard et C.M. Girard, « *Télédétection appliquée : zones tempérées et intertropicales* », Paris, Masson, 1989, 260 pages.
- [Ham 95] D. Hamad et M. Betrouni, « Artificial Neural Networks for Non Linear Projection and Exploratory Data Analysis », *International Conference on Artificial Neural Networks and Genetic Algorithms, ICANN'95*, Alès, France 1995, pp.164-167.
- [Hes 52] M. R. Hestenes, E. Stiefel, « Methods of Conjugate Gradients for Solving Linear Systems », *National Bureau of Standards Journal of Research* 49, 1952, p. 409-436.
- [Hill 89] A. Hillion, J. M. Boucher et C. Roux, « Le Traitement des images de télédétection : Aperçu et Perspectives », *Télédétection en Francophonie*, ED, AUPELF-UREF, JohnLibby, Eurotext, Paris, 1989, p. 83-92.
- [Jai 92] A. K. Jain et J. Mao, « Artificial Neural Networks for Non Linear Projection of Multivariate Data », In *Proc. IEEE Int. Joint. Conf. on Artificial Neural Networks*, Vol 3, Baltimor, Maryland, June 1992, pp. 335-340.
- [Kar 94] J. Karhunen, « Optimisation Criteria and Non Linear PCA Neural Networks », *IEE Inter. Conf. On Neural Networks (NN) Orlando*, Florida, USA, 1994, pp. 1241-1246.
- [Ker 92] P. Kerlizin et P. Refregier, « Robustesse des réseaux neuronaux multicouches : Analyse théorique et application à la compression d'images », *Neuro-Nimes*, 1992, pp. 479-490.
- [Lec 86] Y. Le Cun, « Learning Processin Asymmetric Threshold Network », *Disorder systems and biological Organisation*, E. Bienenstock, F. Fogelman Soulie, and G. Weibush (Eds), Berlin: Springer, 1986.
- [Lec 87] Y. Le Cun, « *Modèles connexionnistes de l'Apprentissage* », *Thèse de Doctorat*, Paris VI, 1987.
- [Lip 87] R.P. Lippman, « An introduction to Computing with Neural Nets » *IEEE ASSP Magazine*, 1987, pp. 4-22.
- [Mat 93] S. Matjek, « L'Analyse Discriminante : Générer des images contractées et orientées pour faciliter l'interprétation forestière », *16<sup>ème</sup> Symposium canadien sur la Télédétection*, Sainte-Foy, Quebec, 1993.
- [Man 91] R. Maniere, H. Khijar et J. Courboules, « Comparaison des différentes méthodes de traitement par analyses en composantes principales des données Thematic Mapper de Landsat-5 Appliquées à l'inventaire des forêts méditerranéennes du Sud de la France », *Int. J. Remote Sensing*, Vol. 12, n° 9, 1991, pp.1897-1903.
- [Rum 86] D. E. Rumelhart, G.E. Hinton et R. J. Williams, « Learning Internal Representation by Error Propagation », *Parallel Distributed Processing : Exploration in Micro Structures of Cognition*, Vol. 1, *Mit Press*, Cambridge, Mass, 1986, pp. 318-362.
- [Rou 98] A. Roukhe, « Neurons Network Processing by a practical Algorithm of Optimization » *International Workshop on Applications of Artificial Neural Networks to Ecological Modelling*, Toulouse, Decembre 1998, pp 14-17.
- [Was 89] P.D. Wasserman, « *Neural computing Theory and Practictise* », VNR, New York, 1989.

Manuscrit reçu le 27 juin 2000

## remerciement

Les auteurs tiennent à remercier les responsables du Centre de Télédétection de la Direction de la Planification et des Affaires Economiques du Ministère de l'Agriculture et la Mise en valeur Agricole (Maroc).

### LES AUTEURS

#### Maria Janati IDRISSE



Maria Janati Idrissi, Diplôme des Etudes Supérieures en Automatique, à l'université Mohamed V à Rabat, Maroc, en 1989. Exerce la fonction du Professeur Assistante à l'université Ibn Tofaïl, Kénitra, Maroc, depuis 1991. Actuellement, elle prépare son doctorat d'état au laboratoire Images et Reconnaissance des Formes (LIRF) de l'université Ibn Tofaïl. Son travail porte sur la classification automatique des données multidimensionnelles par Réseaux de neurones.

#### Raja TOUAHNI



Raja Touahni a obtenu son doctorat de 3<sup>ème</sup> cycle, spécialité électronique, à l'université Paul Sabatier de Toulouse-France, en 1986. Depuis 1987, elle travaille comme Professeur assistante à l'université Ibn Tofaïl, Kénitra, Maroc. Actuellement, elle prépare son doctorat d'état au laboratoire Images et Reconnaissance des Formes (LIRF) de l'université Ibn Tofaïl. Son travail porte sur l'élaboration d'une approche neuro-morphologique pour la classification automatique.

#### Ahmed ROUKHE



Ahmed Roukhe, a obtenu son Diplôme des Etudes Supérieures en Informatique Industriel, à l'université Sidi Mohamed Ben Abdelah, Fès, Maroc, en 1994. Il a soutenu sa thèse d'état à l'université Moulay Ismail, Meknes, Maroc en 1999, où il exerce la fonction de Professeur Habilité. Son travail porte sur le traitement d'images par réseaux de neurones : applications aux mémoires associatives.

#### Abderrahmane SBIHI



Abderrahmane Sbihi, reçoit le « Certificat d'Etudes Universitaires es Sciences » et le « Diplôme de Spécialité de 3<sup>ème</sup> cycle » en transmission et traitement du Signal, respectivement en 1985 et 1988, à l'Université Mohammed V, Rabat, Maroc. Puis il obtient le « Doctorat d'état es Sciences » spécialité reconnaissance des formes, en 1995, à l' Université Ibn Tofaïl (UIT), Kénitra, Maroc. En 1985, il est nommé maître assistant à l'UIT. De 1992 à 1995, il est détaché à l'université des Sciences et Technologies de Lille (USTL), France, où il effectue des recherches au Centre d'Automatique et occupe un poste de Maître de conférence invité à l'Institut de Technologie Appliquée. Depuis 1995, il est Professeur à l'UIT où il crée son laboratoire de recherche : LIRF (Laboratoire Image et Reconnaissance des Formes) en 1998. En 1999, il obtient une bourse d'excellence de l'AUP ELF-UREF d'une durée de six mois pour effectuer des recherches sur l'optimisation des tarifs de cubage du cèdre du Maroc au Centre d'Automatique de l'USTL. Actuellement, il dirige des recherches, au sein du LIRF, portant sur le traitement d'images et la classification automatique des données multidimensionnelles.

#### Abderrahmane AÏT FORA



Abderrahmane Aït Fora a obtenu son doctorat de 3<sup>ème</sup> cycle à l'université de Bordeaux I France en 1986 en géologie du quaternaire. Depuis 1986, il exerce en tant que professeur à l'université Ibn Tofaïl, Faculté des sciences de Kénitra. En 1995 il a soutenu sa thèse de doctorat d'état, spécialité télédétection, à l'université de Sherbrooke (Québec Canada). Son travail de recherche porte sur la modélisation environnementale en utilisant la télédétection et les systèmes d'information géographique.