



1. Introduction

Les images optiques de télédétection sont sujettes à des déformations et à des perturbations dues aux effets atmosphériques, aux vibrations des capteurs, et autres [1]. Ceci se traduit par un bruit additif qui se rajoute au contenu du pixel. Ces images sont corrélées et donc posent le problème de redondance de l'information [2]. L'Analyse en Composantes Principales (ACP) peut être appliquée pour obtenir une représentation optimale de ces images [3]. Cependant, la mise en œuvre de l'ACP souffre de la difficulté d'une évaluation précise de la matrice de transformation linéaire. L'estimation de la matrice de covariance n'est pas une tâche facile lorsque la taille de l'image et/ ou le nombre d'images est important, où nous observons une accumulation des erreurs du calcul. Ainsi, pour une application efficace de l'ACP, une méthode qui détermine avec précision la matrice de transformation linéaire, sans devoir estimer la matrice de covariance et calculer sa décomposition spectrale, est nécessaire. Ceci peut être réalisé en utilisant les réseaux de neurones qui s'adaptent à la nature des données [4].

2. ACP Neuronale : Principe et Modèle

Dans la littérature, un certain nombre de modèles des réseaux de neurones pour l'ACP a été proposé [5]-[7]. Ces modèles ont été inspirés des systèmes biologiques tout en développant ce qu'on appelle l'apprentissage non-supervisé qui est basé sur la règle Hebbienne d'apprentissage [8]. Pour bien illustrer cette règle, considérons un neurone simple ayant comme entrée le vecteur $X=(x_1, x_2, \dots, x_p)^T$ et génère comme sortie la réponse y . L'activation est calculée comme étant le produit inhérent du X par le vecteur des poids synaptiques $W=(w_1, w_2, \dots, w_p)^T$, tel que :

$$u = \sum_{i=1}^p w_i \cdot x_i \quad (1)$$

Quand deux neurones sont simultanément excités, la connexion entre eux est forcée. Selon la règle Hebbienne, le changement dans les poids synaptiques dans un neurone simple est tel que : $\Delta w_i(k) = \beta \cdot y(k) \cdot x_i(k)$ où k est l'itération et β est le paramètre d'apprentissage. La mise à jour des w_i prend la forme suivante :

$$w_i(k+1) = w_i(k) + \beta \cdot y(k) \cdot x_i(k) \quad (2)$$

Le problème avec cette forme de mise à jour est qu'elle mène à une croissance exponentielle de w_i quand le nombre d'échantillons d'apprentissage augmente [9], [10]. L'algorithme de normalisation proposé par Oja dans [10] pour stabiliser les règles d'Hebb consiste à incorporer un terme de normalisation :





$$w_i(k+1) = \frac{w_i(k) + \beta \cdot y(k) \cdot x_i(k)}{\left(\sum_i (w_i(k) + \beta \cdot y(k) \cdot x_i(k))^2 \right)^{1/2}} \quad (3)$$

Pour de petites valeurs de β , l'équation (3) prend la forme approximative suivante :

$$w_i(k+1) = w_i(k) + \beta \cdot y(k) \cdot (x_i(k) - y(k) \cdot w_i(k)) \quad (4)$$

L'équation (4), appelée la règle Hebbienne d'apprentissage généralisée, s'avère être étroitement liée à l'ACP quand les neurones sont représentés par un modèle linéaire. Elle converge vers le vecteur propre principal de la matrice de covariance des données d'entrée [9] et constitue la caractéristique commune de plusieurs algorithmes neuronaux de l'ACP [5]-[11]. Ces algorithmes peuvent être divisés en deux catégories [2] : Algorithmes de réestimation et algorithmes de décorrélation. Dans les algorithmes de réestimation, le réseau de neurones a seulement les coefficients synaptiques connectant les neurones d'entrée aux neurones de sortie. La mise à jour de ces coefficients est basée sur la règle Hebbienne. Avant d'extraire une nouvelle CP, on soustrait les premières CP déjà extraites de l'entrée avant que les données ne soient impliquées dans l'apprentissage. En revanche, dans les algorithmes de décorrélation, le réseau de neurones possède les coefficients synaptiques et les coefficients latéraux. La mise à jour des coefficients synaptiques se fait selon la règle Hebbienne, tandis que la mise à jour des coefficients latéraux est selon la règle anti-Hebbienne d'apprentissage. Les CP ainsi extraites sont décorrélées par annulation des coefficients latéraux durant l'apprentissage.

3. ACP Neuronale d Images de Télédétection

La topologie du modèle neuronal proposé ici pour l'ACP des images de télédétection est présenté dans la figure 1. Les images spectrales d'entrée (vecteur X) sont connectées aux images CP à extraire (vecteur Y) par les coefficients synaptiques (vecteur W). Le modèle utilise ce qu'on appelle les poids latéraux du réseau (vecteur C) qui servent à décorréliser la $m^{ième}$ CP au cours de l'extraction avec les $(m-1)$ CP déjà extraites. L'apprentissage du modèle est basé sur le calcul récursif au sens des moindres carrés "recursive least squares (RLS)" pour extraire la $m^{ième}$ CP sachant que les $(m-1)$ CP ont été déjà extraites. La motivation derrière cette approche est la nécessité d'extraire les CP des données d'entrée dans les situations où le nombre nécessaire des CP à extraire est *a priori* inconnu. L'apprentissage du modèle se fait selon les deux règles suivantes :

$$W_m^{(k+1)} = W_m^{(k)} + \beta_k \cdot (Y_m \cdot X - Y_m^2 \cdot W_m^{(k)}), \quad C_m^{(k+1)} = C_m^{(k)} - \beta_k \cdot (Y_m \cdot X + Y_m^2 \cdot C_m^{(k)}) \quad (5)$$

La première règle, dite adaptative, est la règle Hebbienne d'apprentissage. Elle sert à l'extraction de toutes les CP. La deuxième règle, dite d'orthogonalité inspirée du principe de déflation de matrices, est la règle anti-Hebbienne d'apprentissage. Elle n'est



pas utilisée dans la construction de la première CP. Elle permet de rendre la $m^{\text{ème}}$ CP orthogonale aux $(m-1)$ CP déjà extraites. Le paramètre β_k joue un rôle capital dans la convergence du réseau. Afin de concevoir un algorithme d'apprentissage récursif optimal, l'évolution de β_k doit être cohérente avec la nature des données et l'application envisagée et en même temps ne doit pas conduire à une convergence lente [6], [7]. L'idée est d'intégrer le critère d'optimisation du réseau dans les règles (5) via un choix optimal de la valeur de β_k . Pour cela, nous avons exprimé β_k en fonction de la taille de l'image, N , et de la variance de la CP en cours de construction, $E(y_m^2)$, telle que :

$$\beta_k = 1 / \left(N \cdot E(y_m^2) \right) \quad (6)$$

La mise en œuvre de cette idée a nécessité quelques considérations pratiques afin de rendre le déroulement de l'algorithme d'apprentissage simple et plus rapide. Le réseau se stabilise lorsque les vecteurs W_i convergent vers les vecteurs propres de la matrice de covariance des images spectrales d'entrée, et les vecteurs C_i convergent vers zéro.

4. Résultats Expérimentaux

L'image de télédétection (6 images spectrales, 200x200pixels) de la figure 2 est une image du satellite Landsat-TM, couvrant la région Djebel Amour (Sud de l'Algérie). Aucune information ne peut être extraite à partir de ces images, qui sont sombres et bruitées. L'existence des redondances entre ces images est indiquée par les coefficients de corrélation élevés (tableau 1). Les six images CP extraites en utilisant l'ACP neuronale sont montrées dans la figure 3. Le tableau 2 nous donne les valeurs des rapports signal à bruit "Signal-to-Noise Ratio (SNR)" dans les images spectrales et les images CP. L'amélioration du SNR dans la première image CP par rapport aux images originales est importante. L'essentiel des informations, contenue dans les images spectrales est concentrée maintenant dans la première image CP, qui est une image de très haute qualité. L'information portée par cette image caractérise d'une manière plus précise l'état de surface de la scène observée. Presque toutes les variations de la scène sont visibles dans cette image. La deuxième et troisième image CP sont moins contrastées et le SNR est faible (tableau 2). Néanmoins, quelques caractéristiques et détails de la scène sont encore évidents dans ces deux composantes. Les trois dernières images CP extraites sont dominées par le bruit et l'information portée est négligeable.

Afin d'effectuer une étude comparative, l'ACP statistique est appliquée sur les mêmes données. Pour l'ACP neuronale, la valeur de SNR dans la première image CP est 964,940; ceci correspond à un facteur d'amélioration de 2,2. Pour l'ACP statistique, la valeur du SNR de la première image CP est 960,95. Les autres images CP ont des valeurs de SNR qui sont très différentes des valeurs du SNR de l'ACP neuronale. Pour montrer quelle méthode de l'ACP est la plus précise, nous avons utilisé un critère de mesure la fiabilité dans la compression d'images sans perte importante d'information.

Ceci consiste à reconstituer les images spectrales en utilisant seulement les deux premières images CP. Le degré de similitude entre les images spectrales et les images reconstituées est caractérisé par l'erreur des moindres carrées "Mean-Square-Error (MSE)" : $MSE = \sqrt{E((x_i - \hat{x}_i)(x_i - \hat{x}_i))}$ où x_i et \hat{x}_i sont les images spectrales et reconstituées, respectivement. Les figures 4 et 5 nous donnent les valeurs de MSE pour chaque paire d'images spectrale/reconstituée de l'ACP neuronale et statistique, respectivement. Pour l'ACP neuronale, toutes les valeurs du MSE se trouvent dans l'intervalle [2,5 et 3,75], ce qui reflète une forte ressemblance entre les images spectrales et les images reconstituées. La valeur moyenne du MSE est approximativement égale à 2,987. Cette erreur est acceptable puisque les deux premières images CP représentent 98,87% de la variance totale des images spectrales. Ceci signifie que la méthode neuronale représente un facteur de compression égal à 3. Pour l'ACP statistique, les valeurs du MSE varient de 2,590 à 4,180 et la valeur moyenne de MSE est égale à 3,451. Étant donné que les deux premières images CP de l'ACP statistique représentent 98,43% de la variance totale des images spectrales, nous pouvons dire que le l'ACP neuronale est plus précise que l'ACP statistique puisque sa valeur moyenne correspondante de MSE est plus petite.

5. Conclusion

L'approche neuronale de l'ACP pour l'extraction des CP de l'image de télédétection sans avoir à calculer la matrice de covariance est présentée ici. L'algorithme d'apprentissage a été établi et implémenté de sorte que l'exécution du logiciel développé soit totalement indépendante de l'utilisateur. Les résultats obtenus sur une image de télédétection réelle montrent l'efficacité de l'approche. La capacité de compression de l'ACP neuronale est prouvée en reconstituant les images spectrales avec un minimum d'erreurs au sens des moindres carrés. La précision des résultats est satisfaisante. Une étude comparative entre l'ACP neuronale et l'ACP statistique est effectuée. L'étude comparative a prouvé que l'ACP neuronale est supérieure à l'ACP statistique.

Références

- [1] J. A. Richards and J. A. Xia, *Remote Sensing Digital Image Analysis. An Introduction*, 3rd Edition, Springer-erlag, Berlin, 1999.
- [2] S. Chitroub, *Modélisation, Analyse, Classification et Fusion d'Images de Télédétection Multisources Optiques et Radars*. Thèse de Doctorat d'Etat, Faculté d'Electronique et d'Informatique, U. S. T. H. B, Alger, N°d'ordre : 01/2003-E/EL, Février 2003.



[3] A. J. Richard, and D. W. Wichern, *Applied Multivariate Statistical Analysis*. 2nd Edition, Prentice Hall International, New Jersey, 1988.

[4] S. Haykin, *Neural Networks, a Comprehensive Foundation*, 2nd Edition, Prentice-Hall, 1999.

[5] E. Oja, "Principal components, minor components and linear neural networks", *Neural Networks*, Vol. 5, pp. 927-935, 1992.

[6] S. Y. Kung, K. I. Diamantaras, K. I., and J. S. Taur, "Adaptive principal component extraction (APEX) and applications", *IEEE Transaction on Signal Processing*, Vol. 42, No. 5, pp. 1202-1217, 1994.

[7] S. Bannour, and M. R. Azimi-Sadjadi, "Principal component extraction using recursive least squares learning", *IEEE Transaction on Neural Networks*, Vol. 6, No. 2, pp. 457-469, 1995.

[8] D. O. Hebb, *The Organization of Behavior*, Wiley, New York, 1949.

[9] E. A. Oja, "A simplified neuron model as a principal components analyzer", *Journal of Mathematical Biology*, Vol. 15, pp. 267-273, 1982.

[10] E. Oja, "Neural networks, principal components, and subspaces", *International Journal of Neural Systems*, Vol. 1, pp. 61-68, 1989.

[11] S. Chitroub, A. Houacine, and B. Sansal, "Principal component analysis of multispectral images using neural network", In *Proceedings of ACS / IEEE Inter. Conference on Computer Systems and Application (AICCSA 2001)*, 26-29 June 2001, Beirut, Lebanon, pp. 105-111.




Figure 2. modèle de réseaux de neurone pour l'ACP d images de télédétection.

Images spectrales	1 ^{ère} image	2 ^{ème} image	3 ^{ème} image	4 ^{ème} image	5 ^{ème} image	6 ^{ème} image
1 ^{ère} image	1.000000					
2 ^{ème} image	0.950527	1.000000				
3 ^{ème} image	0.914597	0.977681	1.000000			
4 ^{ème} image	0.893477	0.959884	0.981840	1.000000		
5 ^{ème} image	0.883223	0.937426	0.950577	0.947707	1.000000	
6 ^{ème} image	0.872567	0.939118	0.958085	0.943569	0.980474	1.000000

Tableau 1. Coefficients de corrélation entre les six images spectrales.





SNR dans les images spectrales originales					
1 ^{ère} image	2 ^{ème} image	3 ^{ème} image	4 ^{ème} image	5 ^{ème} image	6 ^{ème} image
45.095375	41.679432	140.698288	142.237122	443.795746	181.927475
SNR dans les images CP (ACP neuronale)					
1 ^{ère} image CP	2 ^{ème} image CP	3 ^{ème} image CP	4 ^{ème} image CP	5 ^{ème} image CP	6 ^{ème} image CP
964.941357	19.277951	7.787135	6.024435	1.486921	0.728147
SNR dans les images CP (ACP statistique)					
1 ^{ère} image CP	2 ^{ème} image CP	3 ^{ème} image CP	4 ^{ème} image CP	5 ^{ème} image CP	6 ^{ème} image CP
960.954285	18.823294	7.699635	5.393777	1.747629	0.815081

Tableau 2. Rapport signal sur bruit (SNR) dans les images spectrales et images Composantes Principales (CP) de l'ACP neuronale et l'ACP statistique.



Image spectrale 1



Image spectrale 2



Image spectrale 3



Image spectrale 4



Image spectrale 5



Image spectrale 6

Figure 3. Les six images spectrales originales fournies par le satellite Landsat-TM. (Région Djebel Amour, Sud de l'Algérie).






Figure 3. Les six images composantes principales de l'ACP neuronale.

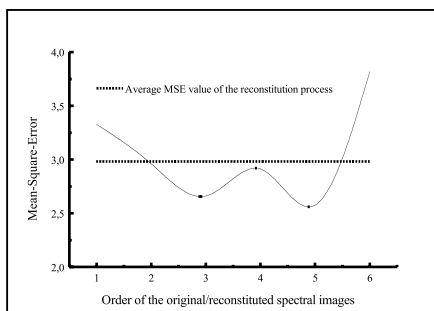


Figure 4. MSE dans la reconstitution (ACP neuronale)

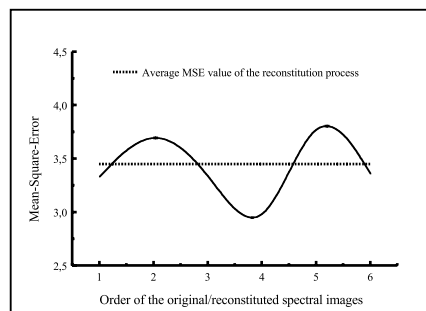


Figure 5. MSE dans la reconstitution (ACP statistique).

