

Influence des paramètres texturaux sur les performances des réseaux de neurones pour la classification d'images de télédétection

MARRAKCHI OLFA^{1,2}, ELGHALI AMIRA¹

¹Institut National des Sciences Appliquées et de Technologie (INSAT)
Centre Urbain Nord, BP 676, 2080, Tunis, Tunisie

²Laboratoire des Systèmes et de Traitement des Signaux
Ecole Nationale d'Ingénieurs de Tunis (ENIT), BP 37 Belvédère 1002, Tunisie

¹Olfa.Marrakchi@enit.rnu.tn

²amira_fginf@laposte.net

Résumé - Cet article concerne l'évaluation des performances des réseaux de neurones (RN) pour l'identification des textures fortement hétérogènes d'images de télédétection. Cette évaluation est réalisée par le biais d'une optimisation en temps d'apprentissage et en nombre de neurones du réseau de neurones sous la contrainte d'atteindre des taux d'identification des textures optimaux. L'étude concerne aussi l'influence de la nature texturale hétérogène sur le choix de certains paramètres neuronaux permettant d'obtenir l'unité élémentaire des textures. Il s'agit d'étudier l'impact de l'information texturale sur la conception de réseaux de neurones et cela en considérant des échantillons de textures présentant une complexité liée à la corrélation texturale ainsi qu'aux pourcentages des taux de recouvrement des espèces contenues dans ces textures. Les bases de textures utilisées sont issues d'images de télédétection de sources différentes à savoir une image radar aéroportée ROS et une autre acquise par le satellite Aster dont les résolutions sont totalement différentes. A cet effet, nous avons étudié l'influence de la résolution spatiale sur les résultats d'identification des textures par la méthode neuronale tout en adoptant la même procédure d'évaluation des résultats de classification et des performances des réseaux relativement à chacune des deux images. Les résultats concernent essentiellement l'analyse des textures selon leurs caractéristiques en terme d'hétérogénéité et de pourcentage du taux de recouvrement ; les critères de choix de l'architecture neuronale et enfin l'influence des paramètres des textures des images pour la détermination de l'architecture optimale du RN ainsi que l'élément unitaire de la texture.

Abstract - This paper deals with the evaluation of Neuronal Networks (NN) performances aiming to identify heterogeneous textures in remote sensing data. This evaluation is realized through the optimization of the spending learning process time and the number of the NN neurons in order to attempt optimal rates of textures identifications. This study concerns the influence of the texture characteristics onto the choice of NN parameters which involve the determination of the texture elementary unit. In fact, we have studied the impact of the textural information on to the conception of the NN architecture and that by considering texture samples with complexity due to the texture correlation and to the percentage of the species cover rates contained in these textures. The textures data sets are issued from remote sensing images which are acquired by different sensors : we have an airborne radar image (SAR) and an Aster satellite image with different resolutions. However, we have focused our study on the influence of the spatial resolution on to the classification results and on to the NN performances relatively to both images. Results interest essentially the texture analysis using their characteristics in terms of heterogeneity and of coverage rates ; the criteria imposing the choice of NN architecture and finally the influence of image textures parameters to determine the optimal architecture of the NN and the texture elementary unit.

1 Introduction

Plusieurs travaux de recherche ont montrés que les classifieurs neuronaux sont des outils assez robustes pour l'identification des textures d'images de télédétection [2][3][6][7]. Cependant, la mise au point de telles réseaux doit être assez judicieuse du point de vu minimisation du temps de calcul, du nombre de neurones par couche et d'assurance pour une convergence vers une solution optimale. Tout ceci est lié à la complexité des données à savoir leurs dimensions et leurs corrélations.

Dans le cas de cette étude nous avons considéré deux images de télédétection à modes d'acquisition différents. Une image acquise par le radar à ouverture

synthétique ROS aéroporté et une autre acquise par le capteur Terra du satellite Aster. Les zones imagées sont à endroits différents du territoire Tunisien (zone semi-aride et zone forestière). Notre intérêt a été porté sur l'influence des paramètres texturaux sur la mise en œuvre de réseaux de neurones capables d'identifier de telles textures sachant que les motifs constituant les textures de telles images sont à détails conditionnés par la résolution spatiale des images (plus la résolution est fine plus il existe des détails).

Dans une première partie de l'article nous avons réalisé une analyse des textures des images tout en relevant la nature de leur complexité. Puis, nous avons mis en évidence le compromis qui existe entre l'élaboration d'une architecture neuronale optimale et

les paramètres texturaux et enfin, nous avons donné les résultats d'identification des textures par les RN tout en évaluant l'impact des paramètres texturaux.

2 Données utilisées

Les bases de textures utilisées sont extraites d'images de télédétection : une image acquise par un radar à ouverture synthétique (ROS) aéroportée fonctionnant en bande C et en polarisation horizontale et une image acquise par le capteur multispectrale Terra du satellite Aster de bandes : Rouge, Verte et Proche Infrarouge. Une étude thématique sur les zones imagées nous a permis d'identifier les différentes textures existantes dans ces images [1][5]. L'effet de la résolution plus fine de l'image ROS, de résolution spatiale de 4.6 mètres, a fait que cette image présente plus de détails que l'image Aster de résolution de 15 mètres (Figure 1).




Figure 1 : de (a) à (d) échantillons de textures extraits de l'image ROS. De (e) à (f) échantillons de textures extraits de l'image Aster

Les échantillons de textures sont différents par leur indice d'hétérogénéité (mélange textural) et par leur pourcentage de recouvrement texturale. Nous avons défini un indice indiquant le niveau d'hétérogénéité de la texture. Ainsi, une texture présentant un mélange de plus de deux textures est supposée fortement hétérogène et son indice, h , est de valeur maximale égale à 3. Pareillement, quand il s'agit d'une texture possédant une texture à recouvrement variable, nous avons attribué à cette texture un indice, r , de pourcentage de recouvrement variant de 1 à 3. Si pour une surface donnée de la zone imagée la couverture est à recouvrement maximale, cet indice est égal à 3 (Tab 1).

Tab 1 : caractéristiques texturales

(a) ($h=2, r=2$) - Oliviers - Sol nu - végétation	(b) ($h=3, r=3$) - Bâtis - Sol nu - végétation
(c) ($h=2, r=1$) - Sol nu - Végétation	(d) ($h=2, r=3$) - Sol nu - Végétation
(e) ($h=2, r=1$) - Chêne liège - Sol nu	(f) ($h=2, r=2$) - Chêne liège - Sol nu
(g) ($h=2, r=3$) - Chêne liège - Sol nu	(h) ($h=2, r=3$) - Pin d'alpes - Chêne liège - Sol nu

3 Critères de choix de l'architecture neuronale

Les réseaux de neurones multicouches [3][4] utilisés pour la classification des images sont formés d'un certain nombre de nœuds d'entrée égal à la dimension de la fenêtre de balayage ($m \times m$) de l'image ; d'un nombre de neurones des couches cachées (1^{ère} couche : n_c , 2^{ème} couche : n_{cc}) adaptés, lors de la phase d'apprentissage du RN, selon la complexité de la texture ; et d'un nombre de neurones de la couche de sortie égal au nombre de classes considérées (4 classes par image). Les neurones effectuent une somme pondérée de leurs entrées par les valeurs des poids synaptiques puis une opération de seuillage selon une fonction d'activation. La fonction d'activation choisie est la fonction sigmoïde, à valeurs extrêmes -1 et 1, puisqu'elle s'adapte au mieux à l'algorithme de rétro propagation du gradient descendant. Les simulations ont été réalisées sous le logiciel Matlab 7.4 (R2007a) utilisant un processeur Intel Core2Quad CPU Q8200 2.33GHz.

Les paramètres utilisés sont d'une part d'ordre structurel tel que le nombre de neurones par couche du réseau ; d'autres paramètres du RN sont plutôt liés à la convergence de l'algorithme d'adaptation des poids synaptiques du RN, tels que, le pas d'apprentissage (μ), l'erreur quadratique moyenne optimale de convergence relative aux exemples d'apprentissage du RN (EQMapprt) et le temps écoulé (T) pour un bon apprentissage. D'autre part, l'ajustement des paramètres concerne aussi les paramètres liés à l'image tels que la dimension de la fenêtre de balayage qui s'adapte selon la complexité texturale (Tab 2) et tout en dépendant des résultats d'identification des textures par le RN.

La conception de l'architecture neuronale s'effectue selon deux phases : la phase d'apprentissage et celle de test. Pendant la phase d'apprentissage, et en partant d'une architecture neuronale dont les paramètres sont fixés aléatoirement (sauf pour le nombre de nœuds d'entrée et le nombre de neurones de sortie), on essaye, après présentation de l'exemple, d'ajuster les valeurs des paramètres selon les critères : minimisation de l'EQMapprt entre la sortie réelle et celle désirée du réseau afin d'atteindre une valeur d'erreur quadratique moyenne minimale (EQMmin) et en satisfaisant les conditions suivantes : une convergence progressive et non fluctuante de l'EQMapprt (conditionnée par le pas μ d'apprentissage) ; une optimisation du nombre de neurones ; une minimisation du temps d'apprentissage et un taux d'identification des textures maximale (1).

$$\tau_{id}(k) = 100 \cdot \sum_{i=1}^c p(I_s = i / k_s = k) / p(k_s = k / I_s = i) \quad (1)$$

Avec c est le nombre de classes considérées, I_s le label du pixel s de l'image classifiée et $p(I_s = i / k_s = k)$ (respectivement $p(k_s = k / I_s = i)$) la probabilité

conditionnelle pour que s soit classé dans la classe i sachant qu'il appartient à la texture k .

La phase de test est réalisée en testant le réseau conçu par des exemples autres que ceux utilisés lors de la phase d'apprentissage (Tab 3 et Tab 4). Dans le cas où le réseau reconnaît ces exemples avec une erreur quadratique moyenne (EQMtest) comparable à EQMapprt alors il est retenu comme candidat. En effet, nous avons obtenu des architectures de réseaux RN qui satisfont le critère de convergence des EQM vers une valeur minimale avec un taux d'identification des textures maximale et un nombre de neurones faible mais ces réseaux présentent l'inconvénient de nécessiter un temps d'apprentissage assez long (RN2 et RN3 du tableau : Tab 4). Dans ce cas, nous n'avons considéré que l'architecture satisfaisant les critères de choix du RN à savoir des valeurs EQMapprt et EQMtest comparables à celle EQMmin pour des valeurs de taux les plus forts tout en attribuant plus d'intérêt au temps d'apprentissage (RN1 des tableaux : Tab4 et Tab 5).

Tab 2 : Nombre d'exemples par image pour l'apprentissage des RN

m	3	5	7	9	11
ROS	3124	2444	1844	1332	908
Aster	1532	1184	880	620	400

Tab 3 : Nombre d'exemples par image pour le test des RN

m	3	5	7	9	11
ROS	1564	1220	924	668	452
Aster	764	592	440	308	200

Tab 4 : paramètres imposant les critères de choix de l'architecture neuronale pour l'image Aster (m=7)

RN	ne	ncc	T	μ	EQMmin	EQMappt
RN1	120	45	14mn	0,05	10-3	0,0369
RN2	120	45	3h49mn	0,05	10-5	0,0035
RN3	5	20	2h15mn	0,07	10-5	0,004

Tab 5 : taux d'identification des textures selon les différentes architectures des RN du Tab 2 (%)

	RN	Classe1	Classe2	Classe3	Classe4
(e)	RN1	95,9	0	4,1	0
	RN2	96,1	0	3,9	0
	RN3	95,3	0	4,7	0
(f)	RN1	0	98,9	1,1	0
	RN2	0	99,1	0,9	0
	RN3	0	98,9	1,1	0
(g)	RN1	0	0	99,3	0,7
	RN2	0	0	98,8	1,3
	RN3	0	0	93,1	6,9
(h)	RN1	0	0,5	0	99,5
	RN2	0	0,4	0	99,6
	RN3	0	0,4	0,1	99,5

4 Influence des paramètres texturaux

Les résultats de l'identification texturales montrent que les valeurs des taux moyens des textures de l'image

ROS sont inférieures à ceux de l'image Aster sachant que les architectures neuronales ont été conçues selon les mêmes critères d'optimisation (Tab 6 et Figure 2). Par conséquent, les paramètres texturaux en résolution spatiale et en nature texturales influent non seulement sur l'architecture neuronale mais aussi sur les performances d'identification des textures par les réseaux de neurones (Tab 7).




Figure 2 : textures classifiées selon les différentes dimensions de fenêtre de balayage (RN1)

Tab 6 : taux moyens d'identification des textures en fonction des dimensions de fenêtres de balayage (%)

m	3	5	7	9	11
ROS	80,55	87,45	90,925	87,825	84,825
Aster	98,325	98,425	98,4	98,675	97,6

La résolution spatiale est un facteur influant aussi bien sur la dimension de la fenêtre d'analyse des textures que sur l'architecture des RN. En effet,

l'élément unitaire caractérisant la texture peut être déterminé à partir de la valeur maximale des taux d'identifications relatifs aux réseaux de neurones conçus selon les différentes dimensions de fenêtres d'analyse des textures (Tab 7).

Les résultats montrent que le nombre de neurones total ($ne+ncc$) pour chaque RN varie considérablement d'une image à l'autre. En effet, ce nombre est d'autant plus important relativement à l'image Aster que celui de l'image ROS dont la résolution est plus fine (Tab 7).

La nature texturale est étudiée selon les différentes combinaisons d'indices (h,i) pour les deux images. Ces indices influent sur les résultats d'identification des textures des images de télédétection. En effet, plus l'hétérogénéité et le pourcentage de recouvrement sont importants plus les réseaux nécessitent un nombre de neurones plus élevé comparativement au nombre de neurones nécessaires au RN pour l'identification des textures dont le pourcentage de recouvrement est faible (Tab 7). Notamment, Ce nombre de neurones varie selon la résolution spatiale des images.

Tab 7 : Influence des paramètres texturaux sur l'architecture neuronale et sur l'identification texturale. (a) image ROS, (b) image Aster

(a)				
Textures	a	b	c	d
$\tau_{id\text{ maximal}}(\%)$	95,2	90,4	90,8	92,5
m	7	7	5	11
$ne+ncc$	100	100	20	100
(h, r)	(2, 2)	(3, 3)	(2, 1)	(2, 3)

(b)				
Textures	e	f	g	h
$\tau_{id\text{ maximal}}(\%)$	97	99,6	99,6	99,8
m	3	9	9	5
$ne+ncc$	20	165	165	260
(h, r)	(2, 1)	(2, 2)	(2, 3)	(2, 3)

5 Conclusion

Dans cet article nous avons mis en évidence l'influence de certains paramètres texturaux pour la conception d'une architecture neuronale optimale capable d'identifier des textures d'images de télédétection. Les bases de textures utilisées sont extraites de deux images de télédétection. Il s'agit d'une image radar ROS aéroportée et d'une image Aster de résolutions spatiale différentes.

Les échantillons de textures extraits des images sont caractérisés par leur indice d'hétérogénéité et par leur pourcentage de recouvrement texturale. Une base d'exemples par image a été conçue pour réaliser l'apprentissage de chaque réseau de neurones (RN). Les paramètres des RN ont été ajustés selon les critères de minimisation de l'erreur quadratique moyenne ainsi que du temps de calcul ; d'optimisation du nombre de neurones et d'obtention de taux d'identification des textures maximales. Pour chacune des deux bases de

textures, nous avons conçu une architecture neuronale répondant aux critères imposés.

Les résultats de l'identification texturales montrent que les valeurs des taux moyens des textures dépendent du mode d'acquisition des données (Aster ou ROS). Aussi, la résolution spatiale ainsi que les différentes combinaisons d'indices caractéristiques des textures des images représentent un facteur influant sur l'architecture neuronale.

6 Références

- [1] Chakroun H. et Marrakchi O. « Evaluating medium resolution image classifications in the Tunisian forest inventory improvement », Symposium GORS, 2008, Damas-syrie, 6 pages.
- [2] Changhui P. et Xuezi W. : « Recent applications of artificial neural networks in Forest Resource Management : An Overview », American Association for Artificial Intelligence, 1999, 8 pages.
- [3] Elghali A. et Marrakchi O. : « Performances des réseaux de neurones pour la classification de textures fortement hétérogènes d'images de télédétection », Congrès TAIMA'09, Hammamet, Tunisie. 4-9 Mai 2009, pp : 625-629.
- [4] Looney C.G. : « Pattern recognition using neural networks, theory and algorithms for engineers and scientists », Edition Oxford university press, USA, 1997, 480 pages.
- [5] Marrakchi O. et Boussema M.R : « Etude comparative entre classifieurs neuronaux et floue pour l'extraction d'informations texturales à partir d'images ROS aéroportées et spatiales », 7ieme journées scientifiques de l'AUPELF-UREF, Saint Foy-Québec, 1997, Canada, 26 pages.
- [6] Shah S.K. et Gandhi V. : « Image classification Based on textural features using artificial neural network (ANN) », IE (I) Journal-ET, 2004, Vol 84, January 2004, pp : 72- 77.
- [7] Subramaniana S., Gata N., Sheffield M., Barhenb J., Toomarianc N. : « Methodology for hyperspectral image classification using novel neural network », Algorithms for Multispectral and Hyperspectral Imagery III. SPIE, 1997, Vol. 3071, Orlando.