

# Optimisation d'un modèle connexionniste pour le traitement des données optiques

*HADRIA Fizazi\_Izabatene*

*Départements Informatique, Faculté des sciences, Université des Sciences  
et de Technologies d'Oran (Mohamed Boudiaf),*

*[hadriafizazi@yahoo.fr](mailto:hadriafizazi@yahoo.fr)*

*TELDA Amghar Yasmina*

*Laboratoire SIMPA, Départements Informatique, Faculté des sciences,  
Université des Sciences et de Technologies d'Oran (Mohamed Boudiaf),*

*[amgharyasmina@yahoo.fr](mailto:amgharyasmina@yahoo.fr)*

## Introduction

L'identification des différents thèmes constituant les images satellitaires est un élément clef pour la détection de changement dans une image. Sur des territoires dépassant la dizaine de km<sup>2</sup>, il est difficile d'envisager un inventaire exhaustif pour enquêter sur le terrain ; la variabilité temporelle de ces informations réduirait d'ailleurs son intérêt.

La réalisation de cette mission conduit à observer la terre et l'atmosphère de façon fréquente et répétée, et vu la diversité des sources de données actuellement disponibles et la non adaptabilité des algorithmes classiques à cette masse à la fois importante et hétérogène de données implique l'exploration et la mise en œuvre de nouveaux outils de traitement d'où la naissance de la télédétection.

Dans ce contexte, les outils de télédétection semblent des moyens d'inventaire et de suivi privilégiés du fait de leur large couverture géographique, du caractère instantané et répété de la mesure et de l'aspect numérique de l'information. Bien que le recours à l'imagerie radar soit de plus en plus fréquente en matière d'identification des zones, les capteurs optiques haute résolution sont encore les plus utilisés avec notamment les scènes des satellites d'observations de la terre de type Landsat TM qui permettent, un suivi évolutif de la variabilité spatio-temporelle de l'occupation du sol.

L'image satellitaire brute est caractérisée par sa grande quantité d'information riche et variée

sous forme numérique. L'interprétation de celle-ci nécessite la mise en place de chaînes de traitement basées sur un ensemble de techniques allant de la mise en forme de l'information : restauration, corrections...jusqu'aux techniques de filtrage, segmentation et **classification** de l'image.

La classification [7], [16] est une étape essentielle du processus de traitement, car elle regroupe les éléments similaires en groupes homogènes, correspondant à des régions de l'espace vectoriel. Pour la classification des données de télédétection, nous avons opté pour une approche neuronale vue sa tolérance au bruit et sa facilité de mise en œuvre. Concrètement, les techniques neuronales [7], [10], [11], [16] sont des outils mathématiques et algorithmiques qui s'avèrent être très puissants et commodes pour résoudre des problèmes complexes telle la classification.

Dans notre article, nous présentons un modèle neuronal combinant le Neural Gaz Croissant Supervisé "SGNG" et le réseau à Fonction Radiales de Base "RBF", pour tirer avantages des données de télédétection, et être en mesure d'extraire de l'information significative de l'image.

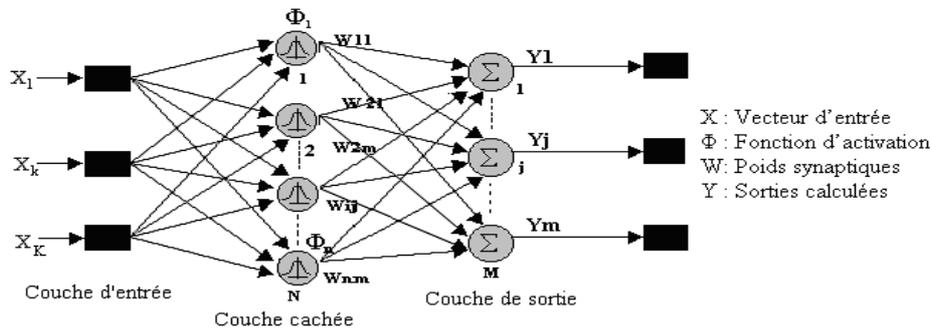
### **Le réseau Radial Basic Functions**

Les réseaux RBF sont utilisés dans différents domaines tel que la reconnaissance des formes [6], [2] [12] la reconnaissance de la langue [5], le traitement de signal [3], le contrôle [4] et le diagnostic d'erreurs [18].

Le réseau RBF [9], [13], [14], [15], [17] est composé de trois couches (cf. *fig. 1*). La couche d'entrée est composée d'une série de nœuds qui récoltent les informations et les transmettent aux neurones de la couche suivante (couche cachée).

Chaque neurone de la couche cachée représente une fonction à base radiale qui réagit aux activations transmises par les neurones d'entrée, [8] la fonction la plus utilisée est la fonction gaussienne. La sortie d'un neurone de la couche cachée est donnée par l'équation (1). Les performances d'un réseau RBF sont conditionnées par sa topologie, c'est-à-dire, le nombre de neurones de la couche cachée, leurs positions et leurs poids de connexion.

Plusieurs algorithmes d'apprentissage du réseau RBF ont été utilisés mais chacun de ces algorithmes souffre de certaines limites. Pour palier cette dégradation, nous proposons une approche hybride utilisant le SGNG et le RBF.



**Figure 1** : Architecture du réseau RBF

$$\phi = f_i(\bar{x}) = P(x, \mu_i, \sigma_i) = \exp\left(\frac{-\|\bar{x} - \bar{\mu}_i\|^2}{2\sigma_i^2}\right) \quad (1)$$

Avec :

$\bar{x}$  : Le vecteur d'entrée,

$\mu_i$  : La position des centres,

$\sigma_i$  : la déviation standard ou la largeur du nœud  $j$ .

L'un des problèmes liés à l'utilisation des RBFs se situe au niveau de la couche cachée, il paraît clair que le résultat dépend étroitement du choix des paramètres liés à la dite couche.

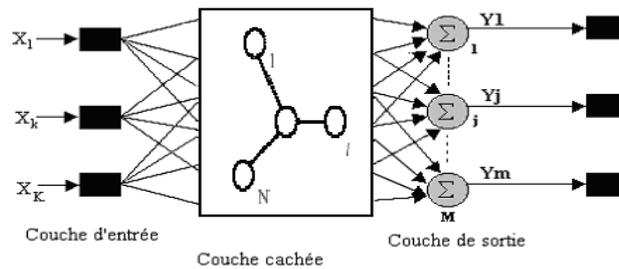
En plus, le choix du nombre de neurones est statique. Afin de palier à ce problème l'idée est de substituer la couche cachée du RBF par une autre, dynamique et notamment celle du GNG, car cet algorithme construit la couche cachée itérativement et de manière incrémentale et vise à décrire la topologie des données est capable de traquer les changements dynamiques. [8]

Les propriétés les plus attirantes dans les réseaux dynamiques sont la vitesse et la garantie de convergence, en faisant ainsi des outils puissants dans la description de la topologie de l'ensemble de données. [1]

### Algorithmes GNG et SGNG :

L'algorithme du GNG comprend un certain nombre de paramètres essentiels [8]. Son apprentissage est du type compétitif.

En ayant un réseau RBF classique avec une couche cachée substituée, dynamique et incrémentale, nous obtenons le réseau RBF-SGNG (cf. fig. 2).



**Figure 2** : Représentation d'un réseau SGNG

Le réseau GNG est un réseau constructif qui ne pose à priori aucune hypothèse sur la topologie de l'espace des entrées. Un réseau minimal est initialement créé et de nouveaux neurones ainsi que de nouvelles connexions entre les neurones sont ajoutées au fil de l'apprentissage non supervisé.

Le SGNG sert à classifier des vecteurs à  $n$  dimensions dans  $M$  classes. Nous aurons un nœud de sortie pour chaque classe. Le nœud de sortie avec la plus grande valeur est le seul à être considéré comme la réponse du réseau RBF.

Nous commençons avec deux nœuds placés aléatoirement connectés par un lien avec ses voisins. L'information du voisin est maintenue par l'application de l'apprentissage compétitif de Hebb (CHL). L'algorithme SGNG peut être décrit comme un réseau RBF avec une version légèrement modifiée de l'algorithme GNG pour la construction de la couche cachée. L'adaptation des nœuds cachés est aussi exécutée en déplaçant le nœud vainqueur  $s$  avec une fraction  $e_w$ , et les voisins de  $s$  avec une autre petite fraction  $e_n$ .

## L'algorithme SGNG :

### Initialisation :

Créer deux nœuds cachés de façon aléatoire, connectés par un lien avec un âge = 0 et mettre leurs erreurs à 0.

Initialiser les poids entre ces nœuds et ceux de la sortie aléatoirement, dans l'intervalle  $[-1, 1]$ .  
[8]

1. Générer un vecteur d'entrée  $\bar{x}$  conforme à la distribution des données.
2. Localiser les deux nœuds  $s$  et  $t$  les plus proches de  $\bar{x}$ .
3. Evaluer le réseau utilisant le vecteur d'entrée  $\bar{x}$ . Ajuster les poids de la couche de sortie par

la règle delta.

4. Modifier l'erreur locale cumulée du nœud gagnant  $s$ .
  5. Déplacer le nœud  $s$  et ses voisins topologiques<sup>1</sup> vers  $\bar{x}$ .
  6. Pour chaque nœud  $j$  qui vient juste d'être déplacé, changer la largeur des nœuds RBF en moyen de la distance entre le nœud  $j$  et ces voisins.
  7. Incrémenter l'âge des liens entre le nœud  $s$  et ses voisins topologiques.
  8. Si  $s$  et  $t$  sont connectés par un lien, alors remettre à zéro l'âge de ce dernier, sinon créer un lien entre eux avec un âge égal à zéro.
  9. S'il y'a des liens avec un âge  $> a_{\max}$  alors supprimer les liens. Si après cette suppression, il y'a des nœuds sans lien alors supprimer ces nœuds. Recalculer les largeurs des RBFs des nœuds affectés.
  10. Si le critère d'insertion (le nombre de nœuds est inférieur à celui recherché) est vérifié, alors insérer un nouveau nœud  $r$  comme suite :
    - a) Rechercher le nœud  $u$  dont l'erreur est maximale.
    - b) Parmi les voisins de  $u$ , trouver le nœud  $v$  dont l'erreur est maximale.
    - c) Insérer le nouveau nœud  $r$  entre  $u$  et  $v$ .
    - d) Crée un lien entre  $u$  et  $r$ , et  $v$  et  $r$ , et supprimer le lien entre  $u$  et  $v$ .
    - e) Recalculer les largeurs RBFs de  $u$ ,  $v$  et  $r$ .
    - f) Décrémenter l'erreur cumulée des nœuds  $u$ ,  $v$  et  $r$ .
    - g) Initialiser les poids entre  $r$  et les nœuds de la couche de sortie, aléatoirement dans l'intervalle  $[-1, 1]$ .
  11. Décrémenter toutes les erreurs cumulées du nœud  $j$  avec le facteur  $\beta$ .
- Si le critère d'arrêt n'est pas atteint alors répéter le processus.

### 3.2. Résultats expérimentaux : [1]

Pour tester la validité de l'approche et évaluer ces performances, le choix a été porté sur des données de télédétection multispectrales TM issues du satellite LANDSAT de la région d'Oran-Ouest.

Vu, que nous avons douze neurones en sortie relatives aux douze thèmes représentant les différentes régions de notre zone étude, nous avons jugé utile de prendre une couche cachée ayant un nombre de neurones supérieur ou égale au nombre de neurones de la couche de sortie. Et pour l'évaluation de nos résultats, nous avons gardé les mêmes échantillons durant tous les tests effectués, ainsi que les constantes de l'algorithme, à savoir :  $e_n=0.006$ ,  $e_w=0.05$  et  $\beta=0.006$  tout au long des tests.

#### 1<sup>er</sup> essai :

---

<sup>1</sup> Les nœuds qui sont connectés à  $s$  par un lien.

Pour notre premier test nous avons fixé le nombre de neurones de la couche cachée (NBR) à 14, et nous avons fait varier le nombre d'itérations (NI).

Le tableau 1 montre le nombre d'itérations et le taux de classification (TC) correspondant.

**Tableau 1 : Résultats expérimentaux**

<b>NI</b>	100	200	300	400
<b>TC</b>	71.47%	71.13%	72.84%	75.13%

Les résultats montrent que plus le nombre d'itérations est faible et plus il y a une confusion entre les différents thèmes constituant notre image (les confusions sont représentés par un cercle noir sur les figures 1 et 2). De même, on constate que pour un nombre d'itérations égal à 400 nous obtenons un taux de classification plus élevé, les confusions entre les classes ont diminué et la confusion entre les classes *Jachère* et *Urbain* à disparue. Donc plus le nombre d'itérations augmente, plus le taux de classification augmente et plus la confusion entre les différentes classes diminue. Il faut noter que cette augmentation se fait aussi au niveau du temps d'apprentissage puisque le temps d'exécution augmente considérablement.

**2<sup>ème</sup> essai :** Pour cet essai, nous avons considéré le même échantillon et les mêmes constantes que précédemment. On prend le nombre d'itérations égal à 400 correspondant au meilleur taux de classification lors du précédent test. Et nous faisons varier le nombre de nœuds dans la couche cachée (NBR).

Les résultats obtenus sont illustrés dans le tableau 2 :

**Tableau 2 : Résultats expérimentaux**

<b>NBR</b>	14	12	18	20
<b>TC</b>	75.13%	75.36%	65.65%	65.31%

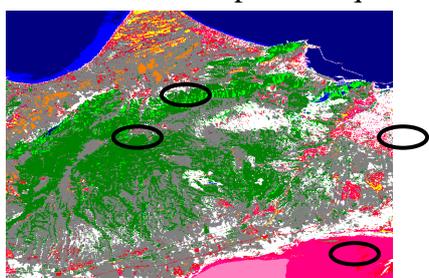
Avec un nombre de nœuds de la couche cachée égal à 12, le taux de classification augmente, et la confusion entre la classe *Maquis* et *Forêt* a disparue.

Avec un nombre de nœuds de la couche cachée égal à 20 le taux de classification diminue

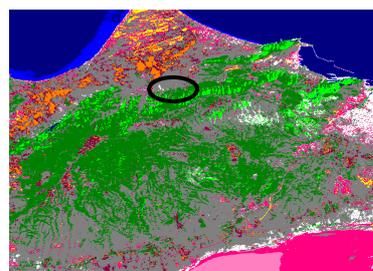
considérablement et un conflit surgit entre la classe *Sebkha1* et *Maraîchage*.

**Remarque :**

Les figures 1 et 2, présentent les résultats obtenus de l'essai 1 et de l'essai 2. Nous présentons dans notre article uniquement le résultat avec plusieurs confusions et le résultat amélioré et cela pour chaque essai.



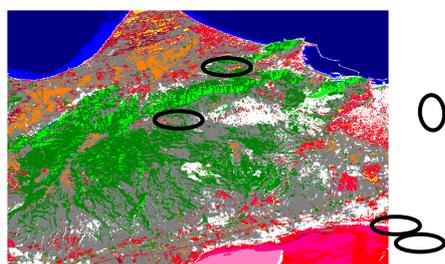
**Fig. 1a:** NI=200, TC=71,13%



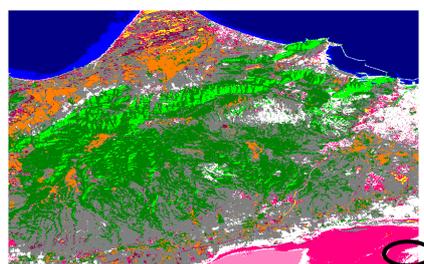
**Fig. 1b:** NI=400, TC=75,13%

Mer	Sable et Sol Nu	Céréale	Forêt	Urbain	Sebkha1
Ressac	Maraîchage	Jachère	Maquis	Brûlis	Sebkha2

**Légende des images classifiées**



**Fig. 2a:** NBR=20, TC=65,31%



**Fig. 2b:** NBR=12, TC=75,36%

**Conclusion :**

La méthodologie de classification que nous avons proposée permet de caractériser la force des méthodes associées à la détection des différentes zones des images.

Les résultats obtenus à travers les plusieurs essais nous permettent de dire que notre algorithme répond aux exigences.

Plus nous augmentons le nombre d'itérations plus le taux de classification augmente et à partir d'un certain seuil le temps d'apprentissage prend le pas sur le taux de classification. Le nombre optimal de nœuds que peut prendre la couche cachée est égal à 12, dépasser ce nombre, le taux de classification diminue inversement avec le taux de confusion. Enfin, le taux de classification dépend fortement des échantillons pris.

De façon plus générale, le modèle proposé semble être plus particulièrement utile dans les situations où l'objectif est de ne pas définir le nombre de nœuds du réseau et plus précisément, dans notre cas, dans la couche cachée. La plupart des algorithmes de classification sont capables de classer une image possédant des frontières clairement définies, mais peu d'algorithmes sont capables d'identifier une zone de transition entre deux classes.

## Références :

1 Y.T. Amghar. « *Classification des données de télédétection par une approche neuronale SGNG : application aux images TM de LANDSAT5* ».

Mémoire de fin d'étude, Université des Sciences et de la Technologie d'Oran. 2006

2 V. Bost, N. Malasné, F. Yang et M. Paindavoine. « *Implémentation d'un réseau de neurones RBF sur des systèmes embarqués : la détection de la reconnaissance de visages en temps réel* ».

Le 2i- FRE CNRS 2309 Aile des Sciences de l'ingénieur. Université de Bourgogne- BR 47870-21078 Dijon - France.2003

3 S. Chen. « *Nonlinear time series modeling and prediction using Gaussian RBF networks with enhanced clustering and RLS learning* ». IEEE Signal Processing Letters, Vol. 31, pp. 117-118. 1995

4 S. Fabri et V. Kadiramanathan. « *Dynamic structure neural networks for stable adaptive control of nonlinear systems* ». IEEE Transaction on Neural Networks, Vol. 7, pp. 1151-1167. 1996

5 M. Ganna et M. Belbraik. « *Elaboration d'un réseau neuronal à base de connaissance pour la reconnaissance automatique de la langue arabe* ».

Mémoire de fin d'études, Université des Sciences et Technologique d'Oran. 2000

6 O. Grzelak. « *Apprentissage supervise et extraction de connaissances à partir des réseaux de neurones de types hyperconvexe* ». Mémoire de stages de DEUA, Illkirch. 2001

7 M. F. Hammadi. « *Classifieur neural d'images de télédétection* ».

Université Louis Pasteur LSIIT UPRES-A 7005 CNRS/ULP, Strasbourg. 1999

8 J. Holmström. « *Growing Neural Gas, Experiments with GNG, GNG with Utility and Supervised GNG* ». Master's Thesis, Uppsala University, Sweden. 2002

9 Howell et Buxton (1998). « *Buxton Learning identity with radial basic function networks* ». Neurocomputing, Vol.20, pp.15-34. 1998

- 10** A. Knippel. « *Utilisation des modèles connexionnistes pour la classification automatique de données satellitaires* ». Mémoire de fin d'étude. 1995
- 11** T. Iftene et H. Fizazi\_Izabatene. « *Approche de classification par réseaux de Kohonen pour établir des cartes d'occupation du sol de la région d'Oran, Algérie* ». IXèmes Journée du réseau Télédétection. 2000
- 12** N. Malasné, F. Yang, M. Paindavoine et J. Mitéran. « *Suivi Dynamique et Vérification de visage en Temps Réel : Algorithme et Architecture* ». 13<sup>ème</sup> RFIA Conférence Francophone, Angers, France. 2002
- 13** J. Moody et C. Darken. « *Learning with Localized Receptive Fields* ». In Proceeding oh the 1988 connectionist Models Summer School, Pittsburgh, PA. 1988
- 14** J. Moody et C. Darken. « *Fast Learning in Networks of Locally-Tuned Processing Units* ». Neural Computation, 1(2): 281-294. 1989
- 15** M. T. Musavi. « *On the training of radial basic function classifiers* ». Neural Networks, Vol.5, pp. 595-603. 1992
- 16** J. Novak. « *Méthode Neurales pour la segmentation d'images de télédétection et l'apprentissage de concepts* ». Université Louis Pasteur LSIIT UPRES-A 7005 CNRS/ULP, Strasbourg. 2000
- 17** T. Poggio et F. Girosi. « *Networks for Approximation and Learning* ». Proceedings of IEEE, 78(9)-1481-1497. 1992
- 18** D. L. Yu, J. B. Gomm and D. Williams. « *Sensor fault diagnosis in a chemical process via RBF neural networks* ». Control Engineering and Practice, Vol. 7, pp. 49-55, 1999.