

Macro Structure Neuronale RBF-IGNG modifiée :

Modélisation de la MES d'Images ALSAT1.

FARID ALILAT¹, SALIHA LOUMI¹, HAMOUD MERRAD¹

¹ Laboratoire de Traitement d'Images et Rayonnement Atmosphérique,
Université des Sciences et de la Technologie Houari Boumediene
BP 32, El-Alia Bab - Ezzouar, 16111, Alger Algérie

¹faralilat@yahoo.fr, salihaloumi@yahoo.fr, merradhamoud@yahoo.fr

Résumé- A travers l'analyse faite sur la famille des Growing Neural Gas architectures évolutive et à apprentissage compétitif non supervisé, des modifications et améliorations en vue de leur association avec le réseau neuronal de modélisation ont été apportées. La modélisation développée se base sur un réseau à fonctions de bases radiales (RBF) associé au neuro-classifieur IGNG (Incremental Growing Neural Gas) et la modification est axée essentiellement sur l'automatisation des paramètres. Pour améliorer les résultats, nous proposons d'élargir les rayons d'influence des *RBF* en multipliant les largeurs des gaussiennes par un facteur recherché de manière automatique afin de minimiser l'erreur de modélisation sur la base d'apprentissage. Une comparaison avec une modélisation par un réseau Perceptron Multi Couches à rétro propagation optimisé par l'algorithme de Levenberg-Marquardt (MLP/LM) est faite. L'objectif de ce travail est la recherche d'algorithmes efficaces permettant de prendre en charge la modélisation et la cartographie des constituants marins. Les images multi spectrales sont acquises par le microsatellite Algérien ALSAT-1. Le constituant modélisé est la Matière En Suspension (MES). La méthodologie développée, les procédures mises en œuvre et les réseaux proposés ont donné des résultats satisfaisants.

Abstract – Through the analysis of the Growing Neural Gas with evolutive architecture and unsupervised competitive learning, modifications and improvements to their association with the neural network modeling have been made. The model developed is based on a network with radial basis functions (RBF) associated with neuro-classifier IGNG (Incremental Growing Neural Gas). The modification is mainly focused on the automation of parameters. To improve the results, we propose to expand the RBF rays by multiplying the widths of the Gaussian by a factor automatically sought to minimize the modeling error on the training set. A comparison with a Multi-Layer Perceptron network which optimized by Levenberg-Marquardt algorithm (MLP / LM) is done. The objective of this work is to looking for efficient algorithms to model and mapping marine components. The Multi spectral images are acquired by the Algerian microsatellite ALSAT-1 and the modeled component is Suspended particulate Matter (SPM). The developed methodology, procedures implemented and the proposed networks have given satisfactory results.

1 Introduction

Les propriétés optiques de plusieurs substances telles que les algues, les matières organiques dissoutes, les particules non organiques en suspension (sable, vase, argile,...) peuvent fortement affecter la couleur de l'eau [1]. La télédétection permet d'estimer la concentration de ces constituants en se basant uniquement sur la couleur de l'eau, ou plus précisément sur sa réflectance spectrale. La matière en suspension est un paramètre difficile à modéliser surtout dans les eaux côtières, vu la variabilité spatio-temporelle de ses constituants [2].

Les propriétés optiques des eaux de cette mer (eaux du Cas 2 : principalement côtières) sont difficiles à caractériser, à l'inverse des eaux du Cas1, où l'évolution des propriétés optiques se fait en fonction des seuls changements de la concentration en chlorophylle ; ces eaux étant soumises aux apports d'eau douce (fluviaux et des oueds), ils sont les bas fonds. En plus des composantes des eaux du Cas 1 (phytoplancton et l'ensemble de ses produits associés tels que les détrit

organiques sous forme de particules ou de substances dissoutes et organismes hétérotrophes), ces eaux contiennent des substances dissoutes exogènes et des particules d'origine sédimentaire ou éolienne. La méthodologie que nous proposons est une modélisation par réseaux de neurones, et sa mise en œuvre nécessite la création d'un masque pour délimiter la région d'intérêt qu'est l'eau. Bien que cette modélisation soit réalisée pour la caractérisation de la matière en suspension (MES), son extension aux autres constituants est aisée et sa zone d'intérêt large (eaux turbides et claires). Les données utilisées sont d'une part, des images multi spectrales du microsatellite de télédétection ALSAT-1[3], et d'autre part, une base d'apprentissage constituée de valeurs MES et des valeurs radiométriques associées dans les bandes de ce capteur. Les réseaux développés et utilisés pour la modélisation est d'une part le réseau à fonctions de base radiale (RBF), associant le réseau neuro-classifieur à carte auto-organisée dynamique IGNG (Incremental Growing Neural Gas) modifié de manière à l'intégrer

dans cette macro structure de modélisation et d'autre part le Perceptron Multi Couches optimisé par l'algorithme Levenberg-Marquardt (PMC/LM) utilisé comme réseau référence de comparaison.

2 Données utilisées

Le site d'étude est la baie d'Alger de coordonnées géographiques $36^{\circ} 44'04N$ à $36^{\circ} 52'09 N$ et $3^{\circ} 01'44 E$ à $3^{\circ} 15'27E$. Les données utilisées représentent une image multi spectrale fournie par le micro satellite Algérien ALSAT-1 acquise le 10 Mars 2003. Nous avons 3 bandes spectrales (rouge, vert, et infra-rouge) de résolution spatiale 32m. Pour éliminer la contribution de l'atmosphère, nous avons utilisé le logiciel ATCOR pour la correction atmosphérique [4]. Pour faire coïncider les positions des données images avec la réalité au sol (mesures *in situ*), un géoréférencement a été effectué. Ce prétraitement a été réalisé à l'aide de six points d'appui en employant la projection UTM, une transformation du type polynomial de degré 1, et l'interpolation du plus proche voisin.

3 Méthodologie de la modélisation

La modélisation de la matière en suspension MES est neuronale. Elle consiste (figure 1) en la présentation au réseau des trois bandes de l'image ALSAT-1, puis la multiplication du résultat par un masque nécessaire à l'isolation de la région d'intérêt qui est l'eau.




Figure 1 : Modélisation de la Matière En Suspension

3.1 Création du masque

Le masque permettant d'isoler la partie eau est réalisé suivant la figure 2. Nous avons utilisé l'algorithme ISODATA associé aux ouvertures/fermetures et aux opérations de reconstruction par dilatation conditionnelle de la Morphologie Mathématique [5]. Par ce procédé, nous avons éliminé les petites aspérités sans toutefois éliminer le lac de Réghaïa, les barrages de Keddara et de l'Oued d'El-Hamiz .




Figure 2 : Schéma bloc de la détermination du masque

La figure 3 illustre le résultat obtenu sur une image acquise le 10/03/2003 par le micro satellite ALSAT-1.




Figure 3 : Masque brut et nettoyé.

3.2 Modélisation neuronale

Les réseaux mis en œuvre dans cette modélisation sont de deux types : le réseau PMC à rétro propagation optimisé par l'algorithme de Levenberg Marquardt (LM) et une macro structure neuronale associant le réseau RBF au réseau à carte auto organisatrice dynamique IGNG modifié (figure 4)

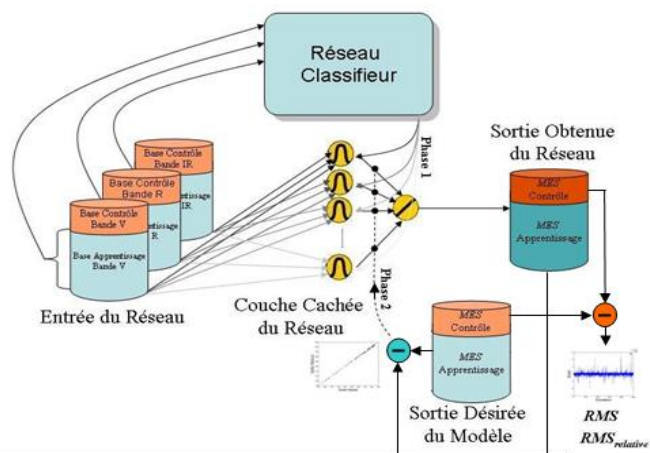


Figure 4 : Réseau hybride RBF/IGNG modifié

4 Réseau à fonctions de bases radiales

L'expression générale de la sortie d'un réseau RBF [6] est :

$$\psi(P) = \sum_{i=1}^{S^l} w_i^2 \phi_i \left(\|P \pm \mu_i\|, \sigma_i^2 \right) \quad (1)$$

Où μ_i est le vecteur (peut être un scalaire) des centres, σ_i^2 un scalaire, P le vecteur (peut être un scalaire) en entrée du neurone RBF, w_i poids liant le neurone RBF i au neurone de sortie ψ et S^l le nombre de RBF. L'apprentissage du réseau est réalisé en deux phases distinctes. La détermination du nombre et des positions des centres est réalisée à l'aide de l'IGNG modifié. Les centres ainsi déterminés seront pris égaux aux vecteurs de références de ces derniers (W_i). Les fonctions de bases testées dans le cadre de ce travail sont des gaussiennes mono et multi variance de la forme :

$$\phi(X) = \exp \left(-\frac{\|X - \mu_i\|^2}{2\sigma^2} \right) \quad (2)$$

Trois (3) largeurs de types hyper sphériques (scalaire) ont été mises en œuvre. Il s'agit :

1. Largeur statistique mise en œuvre pour des fonctions gaussiennes multi variables et multi variance

$$\sigma_{stat}^2(j) = \frac{\sum_{i=1}^{N_j} \|p_i - \mu_j\|^2}{N_j} \quad (3)$$

Où N_j est le nombre d'exemples p_i de la classe c_j de centre μ_j , et $\|\cdot\|$ est la norme l^2 , $j=1, \dots, S'$ et S' est le nombre de nœuds de la couche RBF égal au nombre de classes.

2. Largeur distance pour laquelle chaque neurone RBF possède sa largeur.

$$\sigma_{dist}^2(j) = \max_{p_i \in V(c_j)} \|p_i - \mu_j\|^2 \quad (4)$$

3. La plus grande des distances entre les centres et les exemples associés les plus éloignés est donnée par :

$$\sigma_{max}^2 = \max_{j:1 \rightarrow S'} \max_{p_i \in V(c_j)} \|p_i - \mu_j\|^2 \quad (5)$$

La deuxième phase du processus d'apprentissage consiste à estimer les poids de la couche linéaire de sortie. Cette dernière est réalisée par l'utilisation de la méthode des moindres carrés et de la matrice inverse ou pseudo-inverse.

5 Réseau Incremental Growing Neural Gas

Le réseau Incremental Growing Neural Gas (IGNG) est à cartes auto-organisatrices dynamiques [7][8]. Il possède deux types de neurones : des neurones matures et des neurones embryons. De plus chaque neurone possède un âge et un vecteur de référence, et chaque connexion possède un âge. Initialement le réseau est vide. A chaque itération, nous cherchons le neurone gagnant g_1 . Si celui-ci n'existe pas (réseau vide), un nouveau neurone est ajouté[9]. Afin de vérifier si l'insertion d'un neurone est nécessaire, pour chaque donnée $P(t)$ un test est effectué avant l'apprentissage. Il est défini par la relation suivante :

$$\|P(t) - W_i(t)\| \leq \sigma \quad (6)$$

Où σ est un seuil fixé *a priori*, et i (indice du neurone) Si ce test est vérifié, un neurone de type embryon est inséré, son âge est alors égal à zéro.

Dans le IGNG, le neurone gagnant doit vérifier la condition (7), sinon (figure 6.a), un nouveau neurone est ajouté (figure 6.b) avec $W_{new} = P(t)$.




Figure 6: Insertion d'un neurone quand la donnée à apprendre est trop loin de son neurone gagnant.

Dans le cas où le neurone gagnant g_1 satisfait cette condition, un deuxième neurone g_2 le plus proche de l'entrée courante est recherché suivant l'équation 7. Si g_2 n'existe pas ou s'il est trop loin de l'entrée (ne

satisfait pas le test) (figure 7.a), un nouveau neurone est ajouté et une connexion est créée entre ce neurone et g_1 (figure 7.b).

$$g_2 = \arg \min_{i \in V(t) \setminus \{g_1\}} \|P(t) - W_i(t)\| \quad (7)$$




Figure 7 : Insertion d'un neurone quand la donnée à apprendre est trop loin de son deuxième neurone gagnant.

Si par contre, il existe au moins deux neurones jugés proches de l'entrée (qui satisfont le test), une mise à jour des vecteurs de références est réalisée. Le rayon σ de l'hyper sphère est, sans doute, le paramètre qui requiert le plus de connaissances du problème à traiter [10]. Son choix est donc très délicat. Dans notre application, une modification de l'algorithme du IGNG a été proposée pour automatiser ce choix. A chaque entraînement, ce paramètre évolue de manière itérative en accord avec l'équation 8. Le critère d'arrêt étant la convergence vers le réseau possédant le nombre S' désiré de neurones matures (une certaine tolérance est bien sûr admise).

$$\sigma(k+1) = \frac{s'}{S'} \sigma(k) \quad (8)$$

Où S' est le nombre de neurones matures désirés, s' est le nombre de neurones matures actuels (dans le $k^{\text{ème}}$ entraînement). Le but est d'obtenir le paramètre σ adéquat qui donnerait le nombre de classes (neurones prototypes matures) espérés à la fin de la classification.

6 Résultats et Discussions

Nous avons utilisé pour l'entraînement de ce réseau hybride RBF-IGNG modifié, une base d'apprentissage de 2500 échantillons non répétitifs, et une base de contrôle de 1000 autres échantillons non répétitifs. Une étude de l'influence du nombre de nœuds de la couche RBF a été réalisée en considérant un réseau RBF avec trois (03) nœuds dans la première couche et un nœud à sa couche de sortie. Nous proposons dans notre technique d'élargir les rayons d'influence des RBF en multipliant la largeur de la gaussienne par un facteur λ . La technique consiste à faire varier λ^2 avec un pas (0.1 dans notre application), à réaliser pour chaque cas l'apprentissage et à déterminer la RMS (root mean square). Le critère d'arrêt est une RMS à atteindre en phase d'apprentissage ou un arrêt avant que les fluctuations n'apparaissent. La figure 8 justifie ce phénomène en faisant apparaître l'amélioration des résultats par cette technique. En utilisant cette technique, une expérimentation prenant en compte le nombre de nœuds RBF et le types de largeurs hyper sphériques, à montré que globalement la RMS est

nettement améliorée (elle a été divisée par 10), et que la largeur σ_{dist} offre le meilleur résultat (tableau 1).

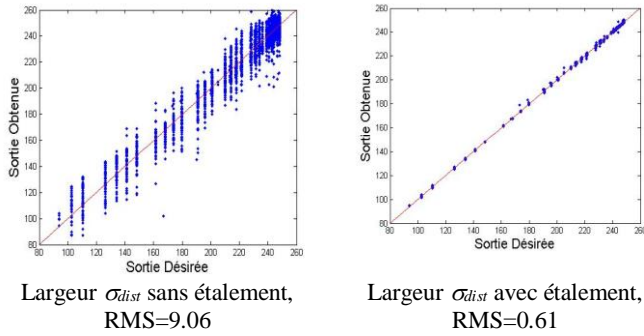


Figure 8 : Performances d'un RBF-IGNG modifié à 20 nœuds RBF

Les résultats du tableau 1, font apparaitre que les *RMS* sont très faibles, inférieur à 0.1 pour un nombre de nœuds RBF supérieur ou égale à 50.

Tab 1 : Apprentissage du réseau RBF- IGNG modifié : RMS et λ pour différentes largeurs.

S nœuds RBF	σ_{dist}		σ_{stat}		σ_{max}	
	λ	RMS	λ	RMS	λ	RMS
20	6.29	0.610	7.07	1.080	2.14	0.400
50	3.77	0.098	6.06	0.083	1.30	0.170
80	3.02	0.051	5.16	0.049	1.00	0.100
100	3.00	0.031	4.99	0.053	1.22	0.079
120	2.86	0.045	4.68	0.046	1.00	0.078
150	2.77	0.027	4.35	0.039	1.05	0.080
200	2.61	0.017	3.94	0.039	1.00	0.110
250	2.26	0.032	4.11	0.052	1.14	0.120

Ces résultats sont équivalents à ceux obtenus avec un nombre de nœuds *RBF* supérieur à 150 dans le cas de gaussiennes à largeurs hyper sphériques. Cette méthode de calcul des largeurs permet donc de diminuer le nombre des *RBF* de la couche cachée, tout en améliorant les performances du réseau. Une comparaison de ce réseau au réseau PMC optimisé par l'algorithme de Levenberg Marquardt avec 10 cellules dans la couche cachée, a été réalisée. Les résultats sont regroupés dans le tableau 2. La modélisation neuronale par le réseau *RBF-IGNG modifié* développée offre de meilleurs résultats.

Tab 2 : Performances du réseau RBF-IGNG modifié et du réseau PMC/LM.

Réseau de modélisation	Apprentissage	Contrôle
RBF-IGNG modifié	0.025	0.027
PMC/LM	0.079	0.077

7 Conclusion

La modification est axée essentiellement sur l'automatisation du rayon de l'hyper sphère d'insertion. L'association du *RBF* à l'*IGNG modifié* dans cette modélisation n'est pas fortuite dans la mesure où nous

cherchons un apprentissage incrémental. Ce dernier est très utile dans le cas où l'entraînement n'est pas réalisé d'un seul trait, ou quand l'apprentissage est amélioré au fur et à mesure que les données entraînant se présentent, ce qui est le cas de notre application où le suivi et la collecte des données s'étalent dans le temps. Une étude sur le type de largeurs des gaussiennes des RBF, leurs formes et leurs étalements a été réalisée, faisant ressortir que le meilleur réseau est un RBF multi variables multi variances à largeur de type hyper ellipsoïdal distance. Nous avons, par cette technique, recherché un facteur multiplicateur global de la largeur. Nous pensons qu'un meilleur résultat pourrait être obtenu si le facteur est recherché localement. Cependant cette technique est très gourmande en temps du calcul.

8 Références bibliographiques

- [1] Thomas Lorthiois. Dynamique des matières en suspension dans le panache du Rhône (Méditerranée occidentale) par télédétection spatiale " couleur de l'océan ". Océanographie. Université Pierre et Marie Curie - Paris VI, 2012. French.
- [2] C. Petus, G. Chust, & all, 2010, Estimating turbidity and total suspended matter in the adour river plume (south bay of biscay) using MODIS 250-m imagery. *Continental Shelf Research*, 30 :379–392.
- [3] Bekhti M., Oussedik A., Cooksley J.R., 2003. Alsat-1: Conception details and in orbit performance. *Actes des Journées Techniques ALSAT 1/Utilisateurs*, Juillet 14 et 15, Alger.
- [4] R. Richter. 2011. Atmospheric / topographic correction for airborne imagery: ATCOR-4 User Guide. DLR IB 565-02/11, Wessling, Germany,
- [5] Coster M. & Cherman J. L., 1985. Précis d'analyse d'images. Éditions du CNRS.
- [6] Powell M. J. D., 1987. Radial basis functions for multivariable interpolation : A review. In J. C. Mason and M. G. Cox, editors, *IMA Conf. Algorithm for Approximation of Functions and Data*, Oxford, UK, Oxford Univ. Press, pp.143-167.
- [7] Fritzsche B., 1995. A Growing Neural Gas Network Learns Topologies. In G. Tesauro, D.S. Touretzky & T.K. Leen (editors), *Advances in Neural Information Processing Systems 7*, MIT Press, Cambridge MA, pp.625–632.
- [8] Ayadi T., Hamdani T., & all, 2007. 2IBGSOM: interior and irregular boundaries growing self-organizing maps. In Sixth International Conference on Machine Learning and Applications (ICMLA 2007),
- [9] L.Vojáček, P. Dráždilová, J. Dvorský, 2014, Combination of Self Organizing Maps and Growing Neural Gas, *Computer Information Systems and Industrial Management*, pp 100-111.
- [10] Quintana-Pacheco Y., Ruiz-Fernández D., & all., 2014, Growing Neural Gas approach for obtaining homogeneous maps by restricting the insertion of new nodes. *Neural Networks*. pages 387 –392