

## **Prédiction des carbonates, des éléments biogènes et détritiques par les réseaux de neurones artificiels dans les dépôts des volcans de boue de la marge atlantique nord marocaine**

*Prediction of carbonates, biogenic and detritic elements by artificial neural networks in the deposits of the north moroccan atlantic margin mud volcanoes*

**Anass LALITI<sup>1\*</sup>, Bouchta EL MOUMNI<sup>1</sup>, Abdelkrim EL ARRIM<sup>1</sup>, Hajar EL MALKI<sup>1</sup>,  
Narjiss ALAOU MHAMMEDI<sup>1</sup>, Habiba OUSMANA<sup>2</sup>, Mohamed BERRADA<sup>3</sup>,  
& Abdellah EL HMAIDI<sup>2</sup>**

1. *Laboratoire d'Environnement, Océanologie et Ressources Naturelles, Département des Sciences de la Terre, Faculté des Sciences et Techniques, Université Abdelmalek Essaadi, BP. 416, Tanger, Maroc, \*(lalilti.anass@gmail.com)*
2. *Equipe Sciences de l'Eau et Ingénierie de l'Environnement, Département de Géologie, Faculté des Sciences, Université Moulay Ismail, BP. 11201, Zitoune, Meknès, Maroc.*
3. *Université Moulay Ismail, ENSAM de Meknès, Laboratoire de Mathématiques et Modélisation Informatique (LM2I), Marjane II, B.P 15290, AL Mansour, 50000, Meknès, Maroc.*

---

**Résumé.** Le présent travail présente une tentative de prédiction des teneurs en carbonates et en éléments détritiques et biogènes en fonction des paramètres granulométriques et minéralogiques des éléments contenus dans les sédiments du Quaternaire terminal recoupés par carottage dans les volcans de boue de la marge atlantique nord marocaine dans Golfe de Cadix. C'est une sorte de modélisation basée sur la méthode des Réseaux de Neurones Artificiels "RNA" de type PMC (Perceptrons multicouches). Elle a été effectuée à l'aide du logiciel Matlab. Les résultats obtenus montrent que les trois paramètres étudiés ont été prédits avec une très bonne précision en utilisant un modèle neuronal de configuration [8 - 4 - 3] avec une fonction d'activation non linéaire de type Sigmoide pour la couche cachée et une fonction d'activation linéaire dans la couche de sortie. Le meilleur choix de l'architecture du réseau réalisé est obtenu grâce aux essais préliminaires. Les réseaux de neurones, performants, ont montré une capacité importante d'apprentissages et de prédiction pour les teneurs en carbonates et en éléments Biogènes et Détritiques. Le coefficient de corrélation R est de 0,98 à 0,99 et l'erreur quadratique moyenne (MSE) est très faible de 0,035 à 0,037 pour la base de données utilisée. Les paramètres étudiés sont liés dans l'ensemble de la base des données avec les paramètres modélisés par une relation non linéaire.

**Mots-clés:** Quaternaire terminal, Volcans de boue, Golfe de Cadix, Marge atlantique marocaine, Prédiction, Réseaux de Neurones Artificiels.

**Abstract.** This work presents a prediction attempt of carbonate and detrital and biogenic elements in depending on granulometric size and mineralogical parameters in the late Quaternary deposits of mud volcanoes in the Gulf of Cadiz and the North Moroccan Atlantic margin. It is a kind of modeling based on the method of Artificial Neural Networks "RNA" type PMC (multilayer perceptrons). It was carried out with the Matlab language that represents a non-recurrent multilayer network based on a supervised learning and the Levenberg Marquardt algorithm. The results, very good, show that the three parameters studied were predicted with high accuracy using a neural model of configuration [8-4 - 3] with a non-linear activation function sigmoid type for the layer hidden and a linear activation function of Purelin in the output layer. Neural networks, very performant, showed significant ability of learning and prediction of carbonates and Biogenic and clastic elements with a correlation coefficient of 0.98 to 0.99, and a very low mean square error from 0.035 to 0.037 for the database used in addition to a better choice of the architecture of the neural network realized through preliminary tests. This shows that the parameters studied in the data set are associated with the modeled parameters by a non-linear relationship.

**Keywords:** Late Quaternary, Mud Volcanoes, Gulf of Cadiz, Moroccan Atlantic margin, Prediction, Artificial Neural Networks.

### Abridged English version

This paper presents an attempt to predict CaCO<sub>3</sub> and detrital and biogenic content depending on the particle size and mineralogical parameters contained in the sediments recovered by coring in the Moroccan North Atlantic margin mud volcanoes in the Gulf of Cadiz. It is a modeling based on the method of Artificial Neural Networks "RNA" type PMC (Multilayer perceptrons). Neural networks are mathematical and computer models, based on assemblies of computational units called formal neurons and inspired by the model of the human nerve cell. They are placed on the one hand in the statistical applications family and on the other hand in the artificial intelligence methods family (Jodouin 1994). This legacy of neurobiology forms an important component of matter, and the concern to maintain a certain correspondence with the human nervous system has animated and continues to animate an important part of the research in the field. Neural networks are generally optimized by statistical learning methods. Despite this legacy, most of today's work focuses on the formal neural network and not its neurobiological correlation. As neural networks, it possess several properties that make them theoretically interesting and very useful from a practical point of view (Jodouin 1994).

Artificial neural networks (RNA) are used as a modern method for approximating complex systems, particularly useful when these systems are difficult to model using conventional statistical methods (Coulibaly *et al.* 1999). They were able to model with great performance the quality of the concrete in the field of civil engineering with prediction of the contents of water and chlorides according to radar observations (Sbartai 2006). They are currently widely used because of their great success in simulating and predicting different parameters related to the characterization and the quality of marine and continental environmental systems. They have been used, for example, to predict the concentrations of NO<sub>2</sub> and nitric oxide NO in Santiago using other environmental variables (Perez *et al.* 2001). Their use also yielded very good results when predicting heavy metal concentrations in fluvial sediments in Morocco, based on a number of physicochemical parameters (Abdallaoui & El Badaoui 2011 and 2014). They have also been applied with great success in predicting the influence of atmospheric nitrogen deposition on water quality in aquatic ecosystems (Palani *et al.* 2011). The prediction of organic carbon and heavy metal concentrations in Pleistocene to Holocene sediments of the Alboran Sea from sedimentological and mineralogical parameters was also with high quality (El Hmaidi *et al.* 2013, Manssouri *et al.* 2014). This type of multilayer perceptrons (PMC) of RNA models has been favored in recent years also for the prediction of hydrological phenomena, although it is still little known to the hydrological community (Coulibaly *et al.* 1999). In

the majority of these previous works, the connectionist approach of RNA was compared with the conventional stochastic method of multiple linear regression RLM. Since 1999, numerous mud volcanoes and diapirs have been discovered in the Gulf of Cadiz and in the North Atlantic margin of Moroccan. In July 2004, several carrots were taken from the Gulf of Cadiz during the TTR14 oceanographic campaign aboard the "RV Professor Logashev". The cores "521G" and "522G" were recovered at the crater of Ginsburg mud volcano, the "525G" core was taken from the top of a dome structure, the "535G" core comes from the base of Meknes mud volcano, and "531G" and "532G" cores belong to the crest of a circular diapiric structure near Kidd mud volcano (Tab. 1, Fig. 1). After opening these cores, the sediments were subjected to several granulometric, petrographic, mineralogical and geochemical analysis (Alaoui Mhammedi Narjisse *et al.* 2008).

The database contains 94 samples (observations). The eight independent variables (explanatory or predictive), correspond to the mineralogical characteristics (% Illite, % Smectite, % Kaolinite, % Chlorite) and granulometric (% Clays, % Silts, % Sand) in addition to the depth of the samples in the studied cores. The three dependent variables (to be explained or to be predicted), correspond to the parameters % CaCO<sub>3</sub>, % Biogenic and % Detritic in the sediments. In general, the database (independent variables) contains raw values with very different values depending on the variables. To be adapted to neural network inputs, the database must undergo pre-processing to standardize measurement scales with data conversion to standardized variables. The database consists of eight independent variables, v1, v2, ....., v8, corresponding to the parameters: Depth (cm), % Smectite, % Illite, % Kaolinite, % Chlorite, % Clays, % Siltes and % Sands. It is normalized between -1 and 1.

The artificial neural network used in our work is a multilayer perceptron network (PMC) type composed of an input layer, a hidden layer and an output layer. It has been chosen for its ease and speed of construction and because our database contains only a limited number of input variables (Manssouri *et al.* 2011). To show the predictive quality of the models, the data used in this study are randomly divided into three groups. The first group, consisting of 60% of the total data, was used to train the system. The second group, containing 20% of the total data, was called to validate the network and the remaining 20% who have not participated in the model learning was used as an independent test to approve the generalization of the model. To choose the best architecture of a neural network, several statistical tests are commonly used. In this work, three statistical tests were used, the correlation coefficient R, the mean square error (MSE) and the absolute mean error (AEM).

The input variables, normalized between -1 and 1, are presented to the eight entries layer of the neural network. They are first multiplied by the weights IW and then added to the bias IB between the input layer and the hidden layer. The neurons in the hidden layer will receive the weighted signals. After addition, they are transformed using a non-linear sigmoid function  $S(x)$ . The generated mathematical model is presented at the input of the output layer. This model will be multiplied by the weights LW and then added to the bias LB that exists between the hidden layer and the output layer. Finally, the result is transformed by a linear function (purelin) F to finally obtain our mathematical model. The Levenberg Marquardt back-propagation algorithm (LM) was used to form the artificial neural network in a fast and robust way, limiting the analysis to networks with a single hidden layer, since this architecture is capable of predicting all outputs.

To determine the best architecture of the network, we used the two criteria MSE and MAE. In order to obtain a generalized model, the two MSE and MAE errors were calculated on the 20% of samples reserved for the test. Once the architecture [8-4-3] of the neural network model is chosen, the model calculates the contents of Carbonate and Detritic and Biogenic elements. The results of this prediction (estimated values) are compared with the values measured by laboratory analysis (observed values) (Figures 6, 7 and 8). The learning base is based on 60% of samples. The network weights and biases are readjusted by the Levenberg Marquardt back-propagation algorithm (LM). Once the parameters have been re-established, the model is tested to determine their accuracy. The validation of the networks is done on 18 samples, which represents 20% of the database. The results confirm again the performance of the neural network with the configuration [8-4-3] with a very good superposition of the curves of the values measured experimentally and those estimated by the RNA model. The statistical parameters of the values estimated by the model of the neural network and those of the observed values are very close for the three modeled parameters (Figures 6, 7 and 8).

In the case of the prediction of Biogenic % and Detritic %, the obtained correlation coefficients are very close to 1 for learning, validation and testing. They decrease slightly in the prediction case of CaCO<sub>3</sub> % (Tab. 2). In the prediction case of Biogenic %, the superposition is excellent between the values observed and those estimated (Fig. 6). The [8-4-3] RNA model gave a correlation coefficient  $R = 0.999$  for learning, validation and test, a mean square error  $MSE = 0.035$  and an absolute mean error  $MAE = 0.154$  (Tab. 2). In the prediction case of the Detritic %, the superposition also remains excellent between the observed and the estimated values (Fig. 7). The [8-4-3] RNA model gave a correlation coefficient  $R = 0.99$  for learning, validation and testing, which is

equivalent to a mean square error  $MSE = 0.036$  and an Absolute mean error  $MAE = 0.153$  (Tab. 2). For the prediction of the CaCO<sub>3</sub> %, the superposition is relatively worse than in the two previous cases between the values observed and those estimated by the [8-4-3] RNA model. It shows a small difference between the observed and the estimated values (Fig 8). The correlation coefficients  $R = 0.96$  for learning,  $R = 0.95$  for validation and  $R = 0.98$  for the test also remain high and correspond to a mean square error of  $MSE = 0.037$  and an absolute mean error  $MAE = 0.155$  (Tab. 2).

The error made by the developed models by every used methods on an individual of the sample used in their construction is called residue (see 2011). In the present study, the relation between the concentrations estimated by the RNA mathematical model and their residuals makes it possible to ensure the performance of the model and to check empirically, among other things, the validity of the model assumptions. Thus, the residuals obtained by the RNA model are markedly scattered and very close to zero (between 0.002 and -0.002) for the prediction of Biogenic % (Fig. 9). These residues vary slightly (between 0.05 and -0.05) for the prediction of Detritic % but are still scarcely dispersed around zero (Fig. 10). They become, however, somewhat more dispersed around zero (between 10 and -10) for the prediction of the CaCO<sub>3</sub> % (Fig. 11). This distribution proves the predictive power of the RNA established model in the prediction of Biogenic %, Detritic % and CaCO<sub>3</sub> % from particle size and mineralogical parameters. In general, the obtained results are very satisfying and justify the use of the artificial neural network approach in the prediction of the environmental parameters in the Northern Moroccan Atlantic margin mud volcanoes sediments. These results are in agreement with those of several previous studies and recent studies that demonstrated the performance of artificial neural network models (Abdallaoui & El Badaoui 2012 and 2014, Bélanger *et al.* 2005, El Badaoui *et al.* 2013a and b, El Hmaid *et al.* 2013, Manssouri *et al.* 2014).

To demonstrate the performance of RNA, the values of the statistical indicators, the correlation coefficient R and the mean square error (MSE) obtained by the RNA model are compared with those obtained with other more classic models specially the multiple linear regression (RLM) model (Table 2). The comparison shows the best quality of the estimations by the RNA model, which shows the lowest values for the statistical evaluation criteria (MSE and MAE) and the high values for the correlation coefficient R. Thus, the performance indicators calculated by the RNA model are significantly different from those of the classical RLM model. The correlation coefficient calculated by the RNA is significantly higher with  $R = 0.99$  for the Biogenic % and the Detritic % and  $R = 0.98$  for the CaCO<sub>3</sub> %, compared to those calculated using the

RLM model which are relatively lower. Moreover, the RNA model generally gives a value of the mean square error (MSE = 0.03) lower than that calculated by the classical RLM model (MSE = 208,58). The mean absolute error shows the same finding with lower values (MAE = 0.15) for the RNA model is generally higher values (MAE = 0.20) for the RLM model (Tab. 2). Several previous work has been carried out to validate their RNA models and their performance by comparing their very satisfying results with those less satisfying in the conventional stochastic method of multiple linear regression RLM

(Coulibaly *et al.* 1999, Abdallaoui & El Badaoui 2011 and 2014, Palani *et al.* 2011, El Hmaidi *et al.* 2013, El Badaoui *et al.* 2013a and b, Manssouri *et al.* 2014). The high-performance neural networks have demonstrated an important learning and prediction capability for the CaCO<sub>3</sub> the Biogenic and Detritic elements for the used database, in addition to a better choice of the architecture of the realized network through preliminary testing. For multiple linear regression, the results are less significant. This shows that the studied parameters in the data set are related to the modeled parameters by a non-linear relation.

## INTRODUCTION

Les volcans de boue font partie des événements géologiques les plus mystérieux de la nature. Des milliers de volcans de boue dans le monde, déterminent et affectent l'habitat et la vie quotidienne des millions de personnes vivant dans leur environnement. Leur distribution est intimement liée à celle de l'activité pétrolière du monde, servant ainsi comme indicateur de ressources naturelles (Kopf 2002). Ils offrent un aperçu au plus profond des processus structurels et diagénétiques tels que la formation des hydrates de gaz, la dissolution des minéraux et leur transformation et la dégradation de la matière organique avec des réactions à haute pression/température (Hensen *et al.* 2007). Ils impliquent généralement des générations et des émissions volumineuses du méthane et du dioxyde de carbone, ce qui fait des volcans de boue une source naturelle de gaz à effet de serre et par conséquent jouent un rôle important dans la dynamique du climat mondial (Etiopie & Milkov 2004, Judd & Hovland 2007).

Ce travail présente une tentative de prédiction des teneurs en CaCO<sub>3</sub> et en éléments détritiques et biogènes en fonction des paramètres granulométriques et minéralogiques contenus dans les sédiments du Quaternaire terminal recoupés par carottage dans les volcans de boue du Golfe de Cadix et de la marge atlantique nord marocaine. C'est une sorte de modélisation basée sur la méthode des Réseaux de Neurones Artificiels "RNA" de type PMC (Perceptrons multicouches). Les réseaux de neurones sont des modèles mathématiques et informatiques, basés sur des assemblages d'unités de calculs appelés neurones formels et dont l'inspiration venait du modèle de la cellule nerveuse humaine. Ils sont placés d'une part dans la famille des applications statistiques et d'autre part dans la famille des méthodes de l'intelligence artificielle (Jodouin 1994). Cet héritage de la neurobiologie forme une composante importante de la matière, et le souci de maintenir une certaine correspondance avec le système nerveux humain a animé et continué à

animer une part importante des recherches dans le domaine. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissage de type statistique. Malgré cet héritage, l'essentiel des travaux d'aujourd'hui ont pour objet le réseau de neurones formels et non sa corrélation neurobiologique. Vu comme des systèmes de calcul, les réseaux de neurones possèdent plusieurs propriétés qui les rendent intéressants d'un point de vue théorique et fort utiles d'un point de vue pratique (Jodouin 1994). Les réseaux de neurones artificiels (RNA) sont utilisés comme une nouvelle méthode d'approximation des systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l'aide des méthodes statistiques classiques (Coulibaly *et al.* 1999). Ils ont pu modéliser avec beaucoup de performance la qualité du béton dans le domaine de génie civil avec prédiction des teneurs en eau et en chlorures en fonction des observables radars (Sbartai 2006). Ils sont actuellement largement utilisés grâce à leur grand succès dans la simulation et la prévision des différents paramètres en relation avec la caractérisation et la qualité des systèmes environnementaux marins et continentaux. Ils ont été utilisés, à titre d'exemple, dans la prédiction de la concentration de NO<sub>2</sub> et de l'oxyde nitrique NO à Santiago à partir d'autres variables environnementaux (Perez *et al.* 2001). Leur utilisation a donné également de très bons résultats lors de la prédiction des concentrations des métaux lourds dans les sédiments fluviaux au Maroc, à partir d'un certain nombre de paramètres physico-chimiques (Abdallaoui & El Badaoui 2011 et 2014). Ils ont été aussi appliqués avec beaucoup de succès dans la prédiction de l'influence des dépôts de l'azote atmosphérique sur la qualité des eaux des écosystèmes aquatiques (Palani *et al.* 2011). La prédiction des concentrations du carbone organique et des métaux lourds était également de très bonne qualité dans les sédiments pléistocènes à holocènes de la mer d'Alboran à partir des paramètres sédimentologiques et minéralogiques (El Hmaidi *et al.* 2013, Manssouri *et al.* 2014). Ce type perceptrons multicouches (PMC) des modèles de RNA a été

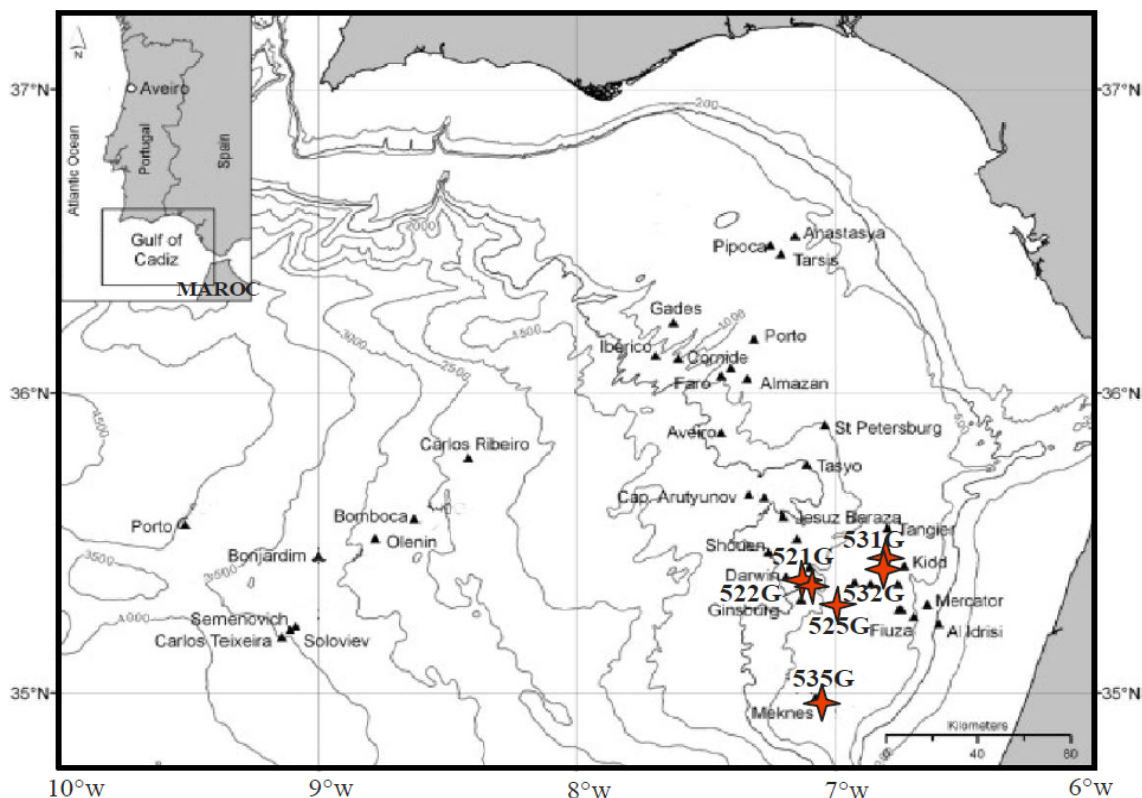


Figure 1. Bathymétrie et physiographie générale du Golfe de Cadix avec distribution des volcans de boue en triangles pleins (Mieiro *et al.* 2007). Les étoiles rouges correspondent aux carottes étudiées.

Figure 1. Bathymetry and general physiography of the Gulf of Cadiz with the distribution of mud volcanoes (Mieiro *et al.* 2007). The red stars correspond to the studied cores.

Tableau 1. Situation et caractéristiques des carottes étudiées.

Table 1. Situation and characteristics of the studied cores.

Site	Carotte	Latitude (°N)	Longitude (°E)	Profondeur d'eau (m)	Longueur de la carotte (cm)
Volcan de boue Ginsburg	521G	35°22,284	7°05,276	919	216
	522G	35°22,417	7°05,299	912	202
Structure en dôme	525G	35°18,228	6°59,692	881	339
	531G	35°26,078	6°46,485	518	80
Structure circulaire	532G	35°26,130	6°46,832	518	107
	535G	34°59,034	7°04,552	718	281

privilegié ces dernières années également pour la prévision de phénomènes hydrologiques malgré qu'il soit encore peu connu de la communauté des hydrologues (Coulibaly *et al.* 1999). Dans la majorité de ces travaux antérieurs, l'approche connexionniste des réseaux de neurones RNA a été comparée avec la

méthode stochastique classique de la régression linéaire multiple RLM.

#### ZONE D'ETUDE

Le Golfe de Cadix se situe au sud de la péninsule ibérique et à l'ouest du détroit de Gibraltar (Fig. 1).

Ouvert à l'ouest sur l'océan atlantique, il est compris entre un domaine continental formé par les plateformes ibériques et marocaines et un domaine océanique représenté par les plaines abyssales (Melières 1974). Son histoire tectonique complexe est gouvernée par l'orogénèse alpine. De point de vue structural, le golfe de Cadix est limité par les failles transformantes Açores-Gibraltar au Nord et par les ceintures alpines du Sud de l'Europe et du Nord de l'Afrique. Il se trouve à cheval sur les frontières des plaques lithosphériques africaine et ibérienne et est délimité à l'Est par l'arc orogénique de Gibraltar (Maldonado *et al.* 1999). Le golfe de Cadix est subdivisé en trois domaines structuraux clés. En effet, le domaine offshore Bético- Rifain s'étend le long du plateau continental et au dessus de la pente moyenne, le domaine central comprend la pente frontale du prisme allochtone, tandis-que le domaine océanique externe correspond aux plaines abyssales "Seine" et "Horseshoe" séparées par la ride de socle "Coral patch ridge" (Medialdea *et al.* 2004).

De point de vue physiographique, le Golfe de Cadix montre un plateau continental étroit de 30 à 40Km de largeur et une pente moyenne de 0,2 à 0,4°. La rupture de pente se trouve vers 120m de profondeur (Fig. 1). La pente continentale laisse apparaître quatre provinces (Nelson *et al.* 1993). En effet, la pente continentale supérieure, inclinée de 2 à 3°, forme une ceinture étroite entre 130 et 400m de profondeur, la pente médiane, située entre 400 et 900m de fond avec une inclinaison inférieure à 1°, est entrecoupée de deux terrasses horizontales, le secteur central entre les terrasses montre des volcans de boue (Pinheiro *et al.* 2003), des vallées de 1 à 3 Km de large et des rides curvilignes étroites, orientées ENE-WSW d'une longueur de 3 à 40Km avec une inclinaison allant jusqu'à 30° et enfin la pente inférieure située entre 900 et 1800m de profondeur, montre une inclinaison de 2 à 4° et de petits canyons de direction NE-SW. Des volcans de boue ont récemment été découverts dans de domaine de pente inférieure et dans les plaines abyssales adjacentes jusqu'à 3500 m de profondeur (Pinheiro *et al.* 2003).

## METHODOLOGIE

### Nature et origine de la base de données

Depuis 1999, de nombreux volcans de boue et diapirs ont été découverts dans le golfe de Cadix et dans la marge atlantique nord marocaine. En Juillet 2004, plusieurs carottes ont été prélevées dans le golfe de Cadix au cours de la campagne océanographique TTR14 à bord du "R/V professeur Logashev". Les carottes "521G" et "522G" ont été récupérées au niveau du cratère du volcan de boue Ginsburg, la carotte "525G" a été prélevée dans le sommet d'une structure en dôme, la carotte "535G" provient de la base du volcan de boue Meknès, et les carottes "531G" et "532G" appartiennent à la crête d'une structure diapirique circulaire près du volcan de

boue Kidd (Tab. 1, Fig. 1). Après ouverture de ces carottes, les sédiments ont fait l'objet de plusieurs analyses granulométriques, pétrographiques, minéralogiques et géochimiques (Alaoui Mhammedi *et al.* 2008).

### Présentation des données et sélection des variables

La base de données contient 94 échantillons (observations). Les variables indépendantes (explicatives ou prédictives), au nombre de huit, correspondent aux caractéristiques minéralogiques (% Illite, % Smectite, % Kaolinite, % Chlorite) et granulométriques (% Argiles, % Silts, % Sables) en plus de la profondeur des échantillons dans les carottes étudiées. Les variables dépendantes (à expliquer ou à prédire), au nombre de trois, correspondent aux paramètres % CaCO<sub>3</sub>, % Biogènes et % Détritiques dans les sédiments.

### Normalisation et prétraitement

En général, la base de données (variables indépendantes) contient des valeurs brutes avec des ordres de grandeurs très différents selon les variables. Pour qu'elle soit adaptée aux entrées du réseau neuronal, la base de données doit subir un prétraitement pour uniformiser les échelles de mesures avec conversion des données en variables standardisées. La base de données se compose de huit variables indépendantes,  $v_1, v_2, \dots, v_8$ , correspondant aux paramètres Prof (cm), % Smectite, % Illite, % Kaolinite, % Chlorite, % Argiles, % Siltes et % Sables. Elle est normalisée entre -1 et 1 selon la relation :

$$v_i = \frac{2[p_i - \text{Min}(p_i)]}{[\text{Max}(p_i) - \text{Min}(p_i)]} - 1$$

$p_i$  : Valeurs normalisées ;  $V_i$  : Valeurs non normalisées ;

$\text{Min}(v_i)$  : Valeurs minimales;

$\text{Max}(v_i)$  : Valeurs maximales.

### Réseau de neurones artificiels

Le neurone formel est l'élément essentiel d'un réseau de neurones. C'est un opérateur mathématique très simple, dont on peut facilement calculer la valeur numérique. Un neurone formel est une fonction algébrique paramétrée, généralement non linéaire en ses paramètres, et à valeurs bornées. Ses entrées peuvent être les sorties d'autres neurones ou des entrées de signaux extérieurs. Sa sortie est une fonction  $f$ , dite fonction d'activation, d'une combinaison linéaire  $A_j$  des entrées ( $P_n$ ). Le potentiel  $A_j$  le plus fréquemment utilisé est la somme pondérée des entrées  $P_n$  pondérées par des coefficients de poids. Son expression est donnée par :

$$A_j = \sum_{i=1}^n W_{nj} P_n + \theta_j$$

où  $W_{nj}$  sont les poids de connexions et  $\theta_j$  est le "biais".

Le fonctionnement du neurone formel est schématisé sur la figure 2.




Figure 2. Schématisation d'un neurone formel.

Figure 2. A formal neuron mapping.

Le réseau de neurones artificiel utilisé dans la présente étude est un réseau de type perceptron multicouche (PMC) composé d'une couche d'entrée, une couche cachée et une couche de sortie. Il a été choisi pour sa facilité et pour la rapidité de sa construction et du fait que notre base de données ne contient qu'un nombre limité de variables d'entrées (Mansouri *et al.* 2011). Pour montrer la qualité prédictive des modèles, les données utilisées durant cette étude sont divisées de façon aléatoire en trois groupes. Le premier groupe, formé de 60% des données totales, servira à entraîner le système. Le deuxième groupe, contenant 20% des données totales, sera appelé pour valider le réseau et les 20% restantes qui n'ont pas participé à l'apprentissage du modèle seront utilisées comme un test indépendant pour approuver la généralisation du modèle.

**Indicateurs statistiques ou tests de robustesse**

Pour choisir la meilleure architecture d'un réseau de neurones, plusieurs tests statistiques sont couramment utilisés. Dans cet article, trois tests statistiques ont été utilisés à savoir le coefficient de corrélation R, l'erreur quadratique moyenne (MSE) et l'erreur moyenne absolue (MAE). Ces essais sont donnés respectivement par les équations suivantes :

$$R = \frac{\sum_i (y_i - \bar{y}_i)(\tilde{y}_i - \bar{\tilde{y}}_i)}{\sqrt{\sum_i (y_i - \bar{y}_i)^2 \sum_i (\tilde{y}_i - \bar{\tilde{y}}_i)^2}}$$

$$MSE = \frac{1}{N} \sum_i (\tilde{y}_i - y_i)^2$$

$$MAE = \sum_{i=1}^N |\tilde{y}_i - y_i|$$

où  $\tilde{y}_i$  est la valeur simulée par le modèle,  $y_i$  est la valeur mesurée,  $\bar{y}_i$  et  $\bar{\tilde{y}}_i$  sont respectivement la

moyenne des valeurs mesurées et estimées et N est le nombre d'échantillons.

**RESULTATS**

**Développement du modèle**

Le réseau de neurones artificiel utilisé dans ce travail est constitué d'une couche d'entrée, une couche cachée et une couche de sortie. Les variables d'entrée, normalisées entre -1 et 1, sont présentées à la couche du réseau de neurones qui contient huit entrées. Elles sont d'abord multipliées par les poids IW et ensuite ajoutées au biais IB qui existe entre la couche d'entrée et la couche cachée. Les neurones de la couche cachée vont recevoir les signaux pondérés. Après l'addition, on les transforme en utilisant une fonction sigmoïde non linéaire  $S(x)$  donnée par l'équation:

$$S(x) = \frac{1}{1 + \exp(-x)}$$

Le modèle mathématique suivant «  $S(IW * P + IB)$  » est présenté à l'entrée de la couche de sortie. Ce modèle sera multiplié par les poids LW puis ajouté au biais LB qui existe entre la couche cachée et la couche de sortie. Finalement, le résultat est transformé par une fonction linéaire (purelin) F. On obtient à la fin le modèle mathématique suivant :

$$F\{LW * S(IW * P + IB) + LB\}$$

L'algorithme de rétropropagation de Levenberg Marquardt (LM) a été utilisé pour former le réseau neuronal artificiel d'une manière rapide et robuste, en limitant l'analyse aux réseaux à une seule couche cachée, vu que cette architecture est capable de prédire toutes les sorties.

**Détermination du nombre de neurones dans la couche cachée**

Pour déterminer la meilleure architecture du réseau, nous avons utilisé les deux critères MSE et MAE. Afin d'avoir un modèle qui généralise le mieux, le calcul des deux erreurs MSE et MAE a été réalisé sur les 20% d'échantillons réservés au test. Les figures 3 et 4 montrent les variations de MSE et MAE en fonction du nombre de neurones dans la couche cachée. Les simulations ont été réalisées afin de déterminer le nombre de neurones nécessaire pour la prédiction des trois paramètres étudiés. Elles ont montré que l'erreur diminue de manière significative à chaque fois qu'on augmente le nombre de neurones dans la couche cachée jusqu'au nombre 4, puis cette erreur ré-augmente. L'architecture du réseau de neurones établie dans cette étude est donc de configuration [8- 4 - 3]. Elle renferme trois couches : une couche d'entrée contenant 8 neurones, une couche cachée contenant 4 neurones et une couche de sortie contenant 3 neurones (Fig. 5).




Figure 3. Variation de l'erreur quadratique moyenne (MSE) sur la partie test des données en fonction du nombre de neurones dans la couche cachée.

Figure 3. Variation of the mean square error (MSE) on the test part of the data as a function depending on the number of neurons in the hidden layer.

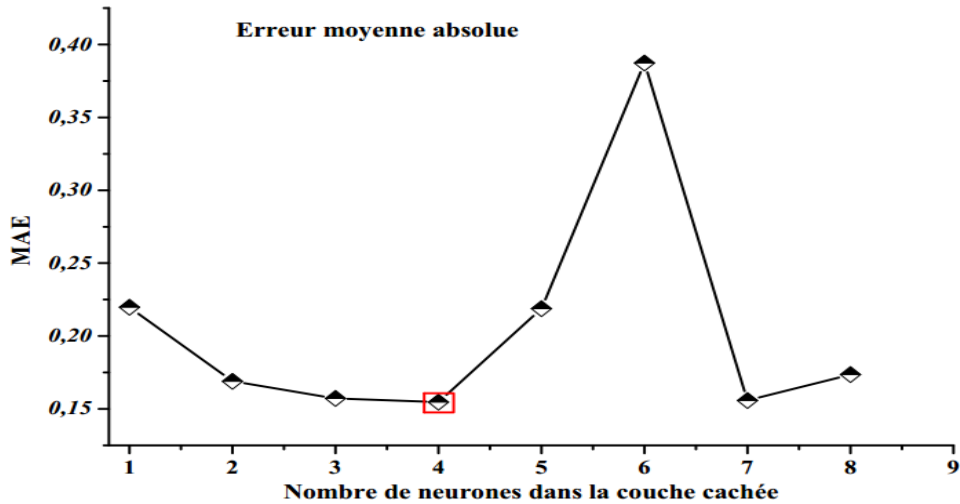


Figure 4. Variation de l'erreur moyenne absolue (MAE) sur la partie test des données en fonction du nombre de neurones dans la couche cachée.

Figure 4. Variation of the absolute mean error (MAE) on the test part of the data as a function depending on the number of neurons in the hidden layer.

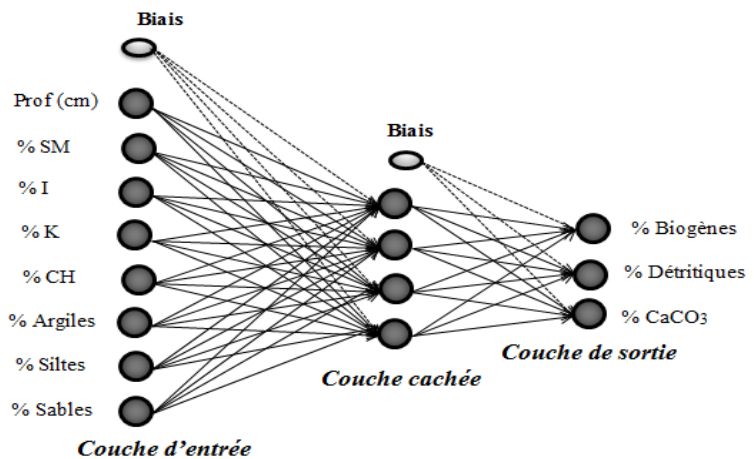


Figure 5. Architecture du réseau de neurones de configuration [8-4-3].

Figure 5. Neural network configuration Architecture [8-4-3].






Figure 6. Résultats de test du modèle RNA-PMC de configuration [8-4-3] pour % Biogènes.

*Figure 6. Test results of the RNA-PMC configuration model [8-4-3] for the Biogenic percentage.*




Figure 7. Résultats de test du modèle RNA-PMC de configuration [8-4-3] pour % Détritiques.

*Figure 7. RNA-PMC configuration test results [8-4-3] for the Detritic percentage.*

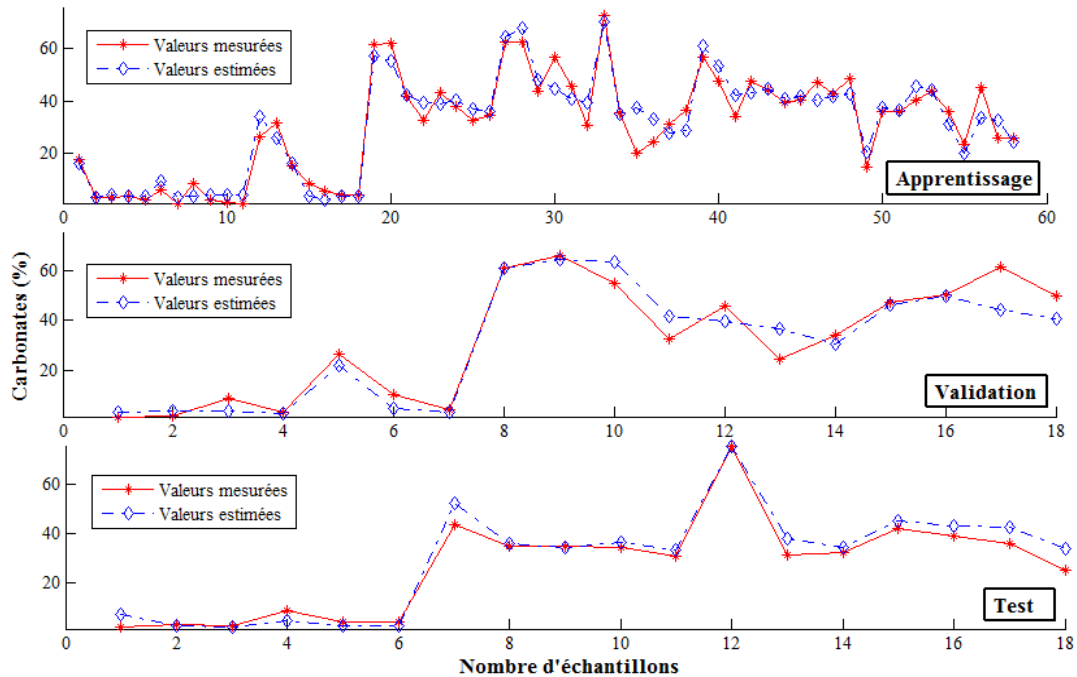


Figure 8. Résultats de test du modèle RNA-PMC de configuration [8-4-3] pour %  $\text{CaCO}_3$ .

Figure 8. Test results of the RNA-PMC configuration model [8-4-3] for the  $\text{CaCO}_3$  percentage.

### Qualité de la prédiction du modèle

Une fois l'architecture [8-4-3] du modèle de réseau de neurones est choisie, le modèle calcule les teneurs en Carbonate et en éléments Détritiques et Biogènes. Les résultats de cette prédiction (valeurs estimées) sont comparés aux valeurs mesurées par analyse au laboratoire (valeurs observées) (Figures 6, 7 et 8).

La base d'apprentissage est fondée sur 60% d'échantillons. Les poids et les biais du réseau sont réajustés par l'algorithme de rétropropagation de Levenberg Marquardt (LM). Une fois les paramètres ré-établis, le modèle est testé pour déterminer leur précision. La validation des réseaux est faite sur 18 échantillons ce qui représente 20 % de la base de données.

Les résultats confirment une autre fois la performance du réseau de neurone de configuration [8-4-3] avec une très bonne superposition des courbes des valeurs mesurées expérimentalement et celles estimées par le modèle RNA. Les paramètres statistiques des valeurs estimées par le modèle du réseau neural et ceux des valeurs observées sont très proches pour les trois paramètres modélisés (Figures 6, 7 et 8).

Dans le cas de la prédiction des % Biogènes et % Détritiques, les coefficients de corrélation obtenus sont très proche de 1 pour l'apprentissage,

la validation et le test. Ils diminuent légèrement dans le cas de la prédiction des %  $\text{CaCO}_3$  (Tab. 2).

Dans le cas de la prédiction des % Biogènes, la superposition est excellente entre les valeurs observées et celles estimées (Fig. 6). Le modèle de réseau de neurone RNA de configuration [8-4-3] a donné un coefficient de corrélation  $R= 0,999$  pour l'apprentissage, la validation et le test, une erreur quadratique moyenne  $MSE= 0,035$  et une erreur moyenne absolue  $MAE= 0,154$  (Tab. 2).

Dans le cas de la prédiction des % Détritiques, la superposition reste également excellente entre les valeurs observées et celles estimées (Fig. 7). Le modèle de réseau de neurone RNA de configuration [8-4-3] a donné un coefficient de corrélation  $R= 0,99$  pour l'apprentissage, la validation et le test, ce équivaut à une erreur quadratique moyenne  $MSE= 0,036$  et une erreur moyenne absolue  $MAE= 0,153$  (Tab. 2).

Pour la prédiction des % $\text{CaCO}_3$ , la superposition est relativement moins bonne que dans les deux cas précédents entre les valeurs observées et celles estimées par le modèle de réseau de neurone RNA de configuration [8-4-3]. Elle montre un petit écart entre les valeurs observées et celles estimées (Fig. 8). Les coefficients de corrélation  $R= 0,96$  pour l'apprentissage,  $R= 0,95$  pour la validation et  $R= 0,98$  pour le test restent aussi élevés et correspondent à une erreur quadratique moyenne de  $MSE= 0,037$  et une erreur moyenne absolue  $MAE= 0,155$  (Tab. 2)

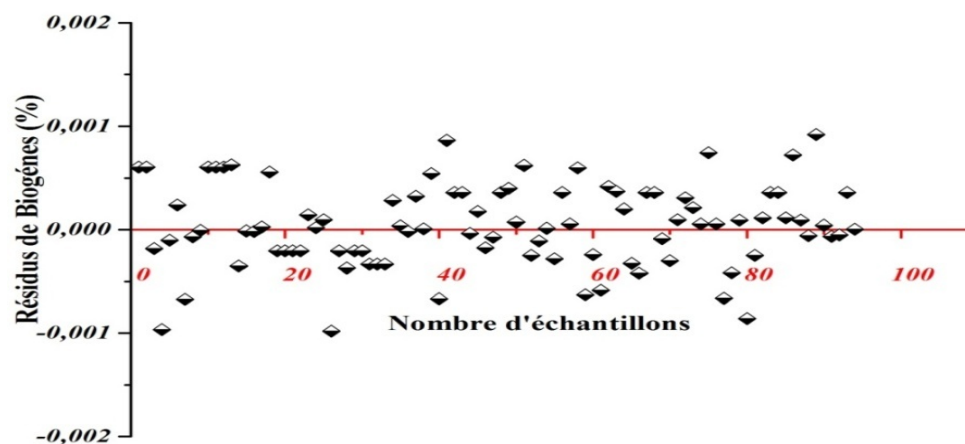


Figure 9. Variation des résidus en fonction du nombre d'échantillons pour la prédiction des % Biogènes.

*Figure 9. Variation of residuals depending on the number of samples for the prediction of the Biogenic percentage.*




Figure 10. Variation des résidus en fonction du nombre d'échantillons pour la prédiction des % Détritiques.

*Figure 10. Variation of residuals depending on the number of samples for the prediction of the Detritic percentage.*




Figure 11. Variation des résidus en fonction du nombre d'échantillons pour la prédiction des % Carbonates.

*Figure 11. Variation of residuals depending on the number of samples for the prediction of the Carbonates percentage.*

Tableau 2. Comparaison des performances de deux modèles RNA et RLM.

Table 2. Performances comparison of the RNA and the RLM models.

Méthodes	% Biogènes			% Détritiques			% CaCO <sub>3</sub>		
	R	MSE	MAE	R	MSE	MAE	R	MSE	MAE
RLM	0,89	208,89	0,285	0,88	208,80	0,285	0,88	50,720	0,085
RNA	0,99	0,035	0,154	0,99	0,036	0,153	0,98	0,037	0,155

### Études des résidus

L'erreur commise par les modèles développés par chacune des méthodes utilisées sur un individu de l'échantillon qui a servi dans leur construction est appelée résidu (Voyant 2011). Dans la présente étude, la relation entre les teneurs estimées par le modèle mathématique RNA et leurs résidus ( $Y_j - Y_i$ ) permet d'assurer la performance du modèle et de vérifier empiriquement, entre autres, le bien fondé des hypothèses du modèle. Ainsi, les résidus obtenus par le modèle des réseaux de neurones sont nettement peu dispersés est très proche de zéro (entre 0,002 et -0,002) pour la prédiction des %Biogènes (Fig. 9). Ces résidus varient légèrement (entre 0,05 et -0,05) pour la prédiction des %Détritiques mais restent toujours peu dispersés autour de zéro (Fig. 10). Ils deviennent, cependant, un peu plus dispersés autour de zéro (entre 10 et -10) pour la prédiction des %CaCO<sub>3</sub> (Fig. 11). Cette répartition prouve la puissance prédictive du modèle établi par les réseaux de neurones dans la prévision des %Biogènes, %Détritiques et %CaCO<sub>3</sub> à partir des paramètres granulométriques et minéralogiques. D'une manière générale, les résultats obtenus sont très satisfaisants et justifient le recours à l'approche par les réseaux de neurones dans la prédiction des paramètres environnementaux dans les dépôts du Quaternaire terminal du golfe de Cadix et de la marge atlantique nord marocaine. Ces résultats sont en accord avec ceux de plusieurs travaux antérieurs et études récentes qui ont démontré la performance des modèles de réseau de neurones artificiels (Abdallaoui & El Badaoui 2012 et 2014, Bélanger *et al.* 2005, El Badaoui *et al.* 2013a et b, El Hmaidi *et al.* 2013, Manssouri *et al.* 2014).

### COMPARAISON ET DISCUSSION

Pour démontrer la performance des réseaux de neurones, les valeurs des indicateurs statistiques, le coefficient de corrélation R et l'erreur quadratique moyenne (MSE), obtenues par le modèle des RNA sont comparées avec celles obtenues avec d'autres modèles plus classiques essentiellement le modèle de la régression linéaire multiple (RLM) (Tab. 2). La comparaison met en évidence la meilleure qualité des estimations par le modèle RNA qui présente, en effet, les plus faibles valeurs pour les critères d'évaluations statistiques (MSE et MAE) et les fortes valeurs pour le coefficient de corrélation R. Ainsi, les indicateurs

de performance calculés par le modèle RNA sont significativement différents de ceux du modèle classique RLM. Le coefficient de corrélation calculé par le RNA est significativement plus élevé avec R= 0,99 pour les %Biogènes et les %Détritiques et R= 0,98 pour les %CaCO<sub>3</sub>, par contre celui calculé à l'aide du modèle RLM est relativement plus faible R=0,89. D'ailleurs, le modèle RNA donne généralement une valeur de l'erreur quadratique moyenne (MSE= 0,03) inférieure à celle calculée par le modèle classique RLM (MSE= 208,58). L'erreur moyenne absolue montre la même constatation avec des valeurs plus faibles (MAE=0,15) pour le modèle RNA est des valeurs généralement plus élevées (MAE=0,20) pour le modèle RLM (Tab. 2). Plusieurs travaux antérieurs ont procédé pour valider leurs modèles de RNA et leur performance à la comparaison de leurs résultats, très satisfaisants, avec ceux moins satisfaisants de la méthode stochastique classique de la régression linéaire multiple RLM (Coulibaly *et al.* 1999, Abdallaoui & El Badaoui 2011 et 2014, Palani *et al.* 2011, El Hmaidi *et al.* 2013, El Badaoui *et al.* 2013a et b, Manssouri *et al.* 2014). Les réseaux de neurones ont été introduits dans l'estimation des paramètres de la distribution Ki-2 Non Centrale Gamma en se focalisant sur une architecture MLP (Perceptron Multi Couches), qui est une architecture aussi simple qu'efficace surtout dans les applications d'approximations de fonctions. Les modèles de réseau de neurones artificiels MLP ont pu donc améliorer considérablement les résultats obtenus par la méthode classique RLM. Dans d'autres travaux, également récents, les réseaux de neurones ont pu améliorer considérablement les résultats obtenus par la détection radar lors de l'estimation des paramètres de la distribution Ki-2 Non Centrale Gamma (Othmani Marabout 2005).

### CONCLUSIONS

La prédiction des teneurs en carbonates CaCO<sub>3</sub> et en éléments Biogènes et Détritiques à partir des données granulométriques et minéralogiques dans les sédiments du Quaternaire terminal recoupés par carottage dans les volcans de boue du Golfe de Cadix et de la marge atlantique nord marocaine a été effectuée à l'aide des réseaux de neurones artificiels RNA de type PMC (Perceptrons multicouches). Les réseaux de neurones utilisés sont à couches non-récurrentes, avec un algorithme de Levenberg

Marquardt et un apprentissage supervisé. Les résultats, de très bonne qualité, montrent que les trois paramètres étudiés ont été prédits avec une très bonne précision en utilisant un modèle neuronal de configuration [8 - 4 - 3] en utilisant une fonction d'activation non linéaire de type Sigmoïde pour la couche cachée et une fonction d'activation linéaire de type Purelin dans la couche de sortie. Les réseaux de neurones, performants, ont démontré une capacité importante d'apprentissages et de prédiction pour les teneurs en carbonates CaCO<sub>3</sub> et en éléments Biogènes et Détritiques avec un coefficient de corrélation de 0,98 à 0,99, une erreur quadratique moyenne très faible de 0,035 à 0,037 et une erreur moyenne absolue de 0,153 à 0,155 pour la base de données utilisée en plus d'un meilleur choix de l'architecture du réseau réalisé grâce à des essais préliminaires. Pour la régression linéaire multiple les résultats sont moins significatifs avec un coefficient de corrélation de 0,88 à 0,89, une erreur quadratique moyenne très élevée de 208,58 et une erreur moyenne absolue de 0,28. Ceci montre que les paramètres étudiés dans l'ensemble des données sont liés avec les paramètres modélisés par une relation non linéaire.

## REMERCIEMENTS

J'exprime mes vifs remerciements à mon directeur de thèse le Professeur Bouchta EL MOUMNI; au Pr Abdelkrim EL ARRIM, responsable du Laboratoire LEORN-FSTT et coordinateur marocain du projet "SEDAPPORT; ainsi que le Pr Luis Menezes Pinheiro et Dr. Vitor Hugo Magalhaes du Laboratoire de GGM de l'Université d'Aveiro; Au Pr Abdellah EL HMAIDI, de l'Equipe SEIE, du Laboratoire GIE de la FS de Meknès. J'exprime toute ma reconnaissance au Dr. Driss ABRID de l'ITSGRT de Meknès; au Dr Mohamed BERRADA du Laboratoire M2I de l'ENSA de Meknès, aussi aux Dr. Narjisse ALAOUI MHAMMEDI, Dr. Habiba OUSMANA et Dr. Morad ABASSI pour leur soutien, leur encouragement, leur présence, leur aide et leur contribution pour compléter et enrichir ce travail. Les évaluateurs anonymes sont remerciés pour leurs remarques et suggestions.

## REFERENCES

- Abdallaoui A. & El Badaoui H. 2011. Prédiction des teneurs en métaux lourds des sédiments à partir de leurs caractéristiques physico-chimiques. *Journal Physical and Chemical News*, 58, 90-97.
- Abdallaoui A., El Badaoui H. & Lancelot L. 2012. Development of a neural statistical model for the prediction of the concentrations of heavy metals (Fe, Mn and Al) in surface waters: case of the Oued Boufekrane, (Meknes, Morocco). *Colloque International Eau et Climat Regards Croises Nord/Sud*, Université de Rouen, p.18.
- Abdallaoui A. & El Badaoui H. 2014. Comparative study of two stochastic models using the physicochemical characteristics of river sediment to predict the concentration of toxic metals. *Journal of Materials and Environmental Science*, 5, 6, 1727-1736.
- Alaoui Mhammedi N., El Moumni B., El Hmaïdi A., *et al.* 2008. Mineralogical and geochemical study of mud volcanoes in north Moroccan Atlantic margin. *African Journal of Environmental Science and Technology*. Vol. 2, 11, 387-396.
- Bélanger M., El-Jabi N., Caissie D. *et al.* 2005. Estimation de la température de l'eau en rivière en utilisant les réseaux de neurones et la régression linéaire multiple. *Revue des sciences de l'eau*, 18, 3, 403-421.
- Coulibaly P., Ancil F. & Bobée B. 1999. Prévision hydrologique par réseaux de neurones artificiels : état de l'art. *Canadian Journal of Civil Engineering*, 26, 293-304.
- El Badaoui H., Abdallaoui A. & Chabaa S. 2013a. Using MLP neural networks for predicting global solar radiation. *The International Journal Of Engineering And Science*, 2, 12, 48-56.
- El Badaoui H., Abdallaoui A. & Chabaa S. 2013b. Etude des effets des algorithmes d'apprentissage et des fonctions de transfert sur la performance des modèles statistiques neuronaux : Application dans le domaine météorologique. *International Journal of Engineering Research and Development*, 9, 6, 15-26.
- El Hmaïdi A., El Badaoui H., Abdallaoui A. *et al.* 2013. Application des réseaux de neurones artificiels de type PMC pour la prédiction des teneurs en carbone organique dans les dépôts du quaternaire terminal de la mer d'Alboran. *European Journal of Scientific Research*, 107, 400-413.
- Etiopie G. & Milkov A.V. 2004. A new estimate of global methane flux from onshore and shallow submarine mud volcanoes to the atmosphere. *Environmental Geology*, 46, 997-1002.
- Hensen C., Nuzzo M., Hornibrook E. *et al.* 2007. Sources of mud volcano fluids in the Gulf of Cadiz—indications for hydrothermal imprint. *Geochimica et Cosmochimica Acta*, 71, 5, 1232-1248.
- Jodouin J. F. 1994. *Les réseaux neuromimétiques, modèles et applications*. Edition Hermès, Paris, 220p.
- Judd A.G. & Hovland M. 2007. *Submarine Fluid Flow, the Impact on Geology, Biology and the Marine Environment*. Cambridge University Press, 475p.
- Kopf A.J. 2002. Significance of mud volcanism. *Reviews of Geophysics*, 40, 2, 1-52.
- Maldonado A., Somoza L. & Pallarés L. 1999. The Betic orogen and the Azores-Gibraltar fracture zone in the Gulf of Cadiz: geological evolution (Central North-Atlantic). *Marine Geology*, 155, 9-43.
- Manssouri I., Manssouri M. & El Kihel B. 2011. Fault Detection by K-NN algorithm and MLP neuronal networks in distillation column. *Journal of information, Intelligence and knowledge*, 3, 57-72.
- Manssouri I., EL Hmaïdi A., Manssouri T. E. *et al.* 2014. Prediction levels of heavy metals (Zn, Cu and Mn) in current Holocene deposits of the eastern part of the Mediterranean Moroccan margin (Alboran Sea). *IOSR Journal of Computer Engineering (IOSR-JCE)*, 16, 1, 117-123.
- Medialdea T., Vegas R., Somoza L. *et al.* 2004. Structure and evolution of the "Olistostrome" complex of the Gibraltar Arc in the Gulf of Cadiz (eastern Central Atlantic): evidence from two long seismic cross-sections. *Marine Geology*, 209, 1-4, 173-198.

- Mélières F. 1974. *Recherches sur la dynamique sédimentaire du Golfe de Cadix (Espagne)*. Doctorat d'Etat, Université Paris VI, n°A10206, 235p.
- Mieiro C.L., Pato P., Pereira E. *et al.* 2007. Total mercury in sediments from mud volcanoes in gulf of Cadiz. *Marine Pollution Bulletin*, 54, 9, 1539-1544.
- Nelson C. H., Baraza J. & Maldonado A. 1993. Mediterranean undercurrent sandy contourites, Gulf of Cadiz, Spain. *Sedimentary Geology*, 82, 103-131.
- Othmani Marabout F. 2005. *Utilisation des réseaux de neurones dans l'estimation des paramètres de la distribution Ki-2 Non Centrale Gamma*. Mémoire de Magister en électronique, Université de Mentouri-Constantine, Faculté des Sciences de l'Ingénieur, Constantine, Algérie, 79p.
- Palani S., Tkalich P., Balasubramanian R. *et al.* 2011. ANN application for prediction of atmospheric nitrogen deposition to aquatic ecosystems. *Marine Pollution Bulletin*, 62, 1198-1206.
- Perez P. & Trier A. 2001. Prediction of NO and NO<sub>2</sub> concentrations near a street with heavy traffic in Santiago. *Atmospheric Environment*, 35, 1783-1789.
- Pinheiro L., Ivanov M.K., Sautkin A. *et al.* 2003. Mud volcanism in the Gulf of Cadiz: results from the TIR-10 cruise. *Marine Geology*, 195, 131-151.
- Sbartai Z. M. 2006. Radar et Réseaux de Neurones Artificiels appliqués à l'évaluation non destructive des teneurs en eau et en chlorures des bétons. 24<sup>ème</sup> Rencontres Universitaires de Génie Civil, Prix Jeunes Chercheur, La Grande Motte, Nîmes, France, 1-8.
- Voyant C. 2011. *Prédiction de séries temporelles de rayonnement solaire global et de production d'énergie photovoltaïque à partir de réseaux de neurones artificiels*. Doctorat en physique, Université de Corse-Pascal Paoli, Ecole doctorale Environnement, Société / UMR CNRS 6134 (SPE), 257p.

Manuscrit reçu le 15/05/2017  
Version révisée acceptée le 29/12/2017  
Version finale reçue le 30/12/2017  
Mise en ligne le 31/12/2017