

Perceptron Multicouches et réseau à Fonction de Base Radiale pour la prédiction du taux d'humidité

[Multilayer Perceptron and Radial Basis Function network to predict the moisture]

Hicham EL BADAOUI¹, Abdelaziz ABDALLAOUI¹, and Samira CHABAA²

¹Department of Chemistry, Analytical Chemistry and Environment Team,
Moulay Ismail University, Faculty of Science,
BP. 11201, Zitoune Meknes, Morocco

²Industrial engineering Department,
Ibn Zohr University, National School of Applied Sciences,
BP. 1136, Agadir, Morocco

Copyright © 2014 ISSR Journals. This is an open access article distributed under the **Creative Commons Attribution License**, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT: This work presents the development of an artificial neural network model based on the Multi-layer Perceptron (MLP) and Radial Basis Function (RBF) for predicting the moisture in the zone of Chefchaouen (Morocco). Our objective is to treat a chronological series of measured data for network response evaluation. For this reason, we used a basic learning neural model for the years 2008 and 2013, the latter consists of a number of meteorological parameters such as humidity, temperature of the air, dew point temperature, air pressure, visibility, cloud cover, wind speed and rain. To determine the network architecture to be used, we varied the number of hidden number of neurons in hidden layers, transfer functions and pairs of transfer functions and learning algorithms. Models performances have been evaluated and developed through the study of the Mean Squared Error (MSE) and correlation coefficient (R). We demonstrated in this study for the prediction of moisture, the best performing model is the one used as transfer functions, the Tansig function in the hidden layer and the Purelin function in the output layer, while using a learning algorithm LM, PMC type of configuration [7-5-1].

KEYWORDS: Moisture, Artificial neural networks, PMC, RBF, Prediction, Learning algorithms.

RESUME : Ce travail présente le développement des modèles statistiques neuronaux de type Perceptron Multicouches (PMC) et réseau à Fonction de Base Radiale (RBF) pour la prédiction du taux d'humidité de la zone de Chefchaouen (Maroc). Notre objectif est de traiter une série chronologique des données mesurées entre les années 2008 et 2013 pour évaluer la réponse du réseau. Cette série est constituée d'un certain nombre de paramètres météorologiques telles que le taux d'humidité, la température de l'air, la température de rosée, la pression atmosphérique, la visibilité, la nébulosité, la vitesse du vent et la précipitation. Pour déterminer l'architecture du réseau à utiliser, nous avons varié le nombre des couches cachées, le nombre de neurones dans une couche cachée, les fonctions de transfert et les couples de fonctions de transfert ainsi que les algorithmes d'apprentissage. Les performances des modèles ainsi développés ont été évaluées grâce à l'étude de l'erreur quadratique moyenne (MSE) et le coefficient de corrélation (R). Nous avons montré par cette étude que pour la prédiction du taux d'humidité, le modèle le plus performant est celui qui utilise comme fonctions de transfert, la fonction Tansig dans la couche cachée et la fonction Purelin dans la couche de sortie, tout en utilisant un algorithme d'apprentissage LM, de type PMC de configuration [7-5-1].

MOTS-CLEFS: Taux d'humidité, Réseau de neurones artificiels, MLP, RBF, Prédiction, Algorithmes d'apprentissage.

1 INTRODUCTION

Les modèles statistiques neuronaux sont des techniques très puissantes pour des données non linéaires. De ce fait, ils ont été appliqués dans divers domaines, notamment en climatologie et particulièrement en météorologie. Les réseaux de neurones artificiels (RNA) ont été utilisés pour approximer la relation entre les différentes variables météorologiques. Différentes études sont proposées dans la littérature à savoir :

Abdelli et *al.* [1] ont utilisé la méthode des réseaux de neurones de type perceptron multicouches, pour la prévision des polluants d'air. Leur objectif est de prévoir les concentrations de NO₂ et de trouver ses relations avec les autres variables météorologiques. Ils ont démontré que la concentration du NO₂ est une variable qui n'agit pas seule, mais elle est expliquée par d'autres variables, telles que la vitesse du vent, la direction du vent, la température et l'humidité.

Cheggaga et *al.* [2] ont développé et mis au point un logiciel qui permet l'estimation et la prédiction de la vitesse de vent dans le temps et dans l'espace en trois dimensions (rayon *r*, hauteur *h*, temps *t*), à base des réseaux de neurones, pour un apprentissage de quelques jours. Ils ont montré la possibilité de l'utilisation des réseaux de neurones à couches non-récurrentes pour l'extrapolation, la prédiction et l'interpolation de la vitesse de vent à partir des données météorologiques.

Abdallaoui et El Badaoui [3] ont utilisé les RNA pour le développement d'un modèle performant pour la prédiction des concentrations des métaux lourds dans les sédiments fluviaux marocains, à partir d'un certain nombre de paramètres physico-chimiques.

Bélanger et *al.* [4] ont utilisé aussi les réseaux de neurones multicouches pour la prédiction de la température de l'eau à partir des paramètres hydrométéorologiques, en se basant sur le modèle de l'intelligence artificiel.

L'objectif de la présente étude est le développement d'un modèle neuronal pour la prédiction des variations du taux d'humidité en fonction de variables météorologiques. Pour cette raison, nous avons utilisé les réseaux de neurones de type perceptron multicouches et les réseaux à fonction de base radiale, à cause de leurs structures simples, de leur utilisation dans une grande variété de problèmes de prédiction et de leurs aptitude à réaliser une transformation arbitraire des entrées vers les sorties.

2 MATERIEL ET METHODES

2.1 BASE DE DONNEES

Dans cette étude, nous avons utilisé une base de données qui est constituée de 1856 jours et huit variables météorologiques de la zone de Chefchaouen (Fig. 1). Ces variables sont définis comme suit :

- Sept variables indépendantes (explicatives) : la température de l'air (T_a), la température de rosée (T_r), la pression atmosphérique (P_a), la visibilité (Vis), la nébulosité ($Néb$), la précipitation (P_r) et la vitesse de vent (V).
- Une variable dépendante (à expliquer) : le taux d'humidité (H).

Les valeurs de ces variables ont été relevées toutes les quatre heures pendant 1856 jours entre les années 2008 et 2013. Elles ont été converties en moyennes journalières pour toutes les variables, sauf pour la précipitation (la quantité de pluie) qui est été transformée en une valeur cumulative de toute la journée [5].




Fig. 1. Situation géographique de la zone de Chefchaouen

2.2 MISE EN FORME DES DONNEES

Les données d’entrée (variables indépendantes) sont des valeurs brutes non transformées qui ont des ordres de grandeurs très différents selon les variables. Afin d’uniformiser les échelles de mesures, ces données ont été converties en valeurs standardisées. En effet, les valeurs I_i de chaque variable indépendante (i) ont été standardisées par rapport à sa moyenne et son écart-type suivant la relation [6], [7], [8]:

$$\hat{I}_i = \frac{I_i - \mu_i}{\sigma_i} \tag{1}$$

\hat{I}_i : Valeur standardisée relative à la variable i ;

I_i : Valeur brute relative à la variable i ;

μ_i : Valeur moyenne relative à la variable i ;

σ_i : écart-type relative à la variable i .

Les valeurs correspondantes aux variables dépendantes ont été également normalisées dans l’intervalle [-1,1] à partir de la relation suivante [9]:

$$\hat{I}_i = \frac{2(I_i - \text{Min}(I_i))}{(\text{Max}(I_i) - \text{Min}(I_i))} - 1 \tag{2}$$

3 RESEAUX DE NEURONES ARTIFICIELS (RNA)

Les réseaux de neurones artificiels constituent une nouvelle approche de modélisation des systèmes complexes, particulièrement utile lorsque ces systèmes sont difficiles à modéliser à l’aide des méthodes statistiques classiques. Les réseaux de neurones artificiels sont issus des premiers travaux réalisés dans le domaine de l’intelligence artificielle pour modéliser le fonctionnement du cerveau humain en se basant principalement sur le concept des neurones. Il s’agit d’un modèle empirique non linéaire [10], [11].

3.1 MODELE MATHEMATIQUE D’UN NEURONE ARTIFICIEL

Le modèle mathématique d’un neurone artificiel est illustré par la figure 2. Un neurone est essentiellement constitué d’un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat de cette somme ensuite transformée par une fonction de transfert f qui produit la sortie O_n du neurone.

Les n entrées du neurone correspondent au vecteur noté: $\vec{I} = (I_1; I_2; I_3; \dots; I_n)$

Le vecteur de poids est représenté par : $\vec{W} = (W_1; W_2; W_3; \dots; W_n)$

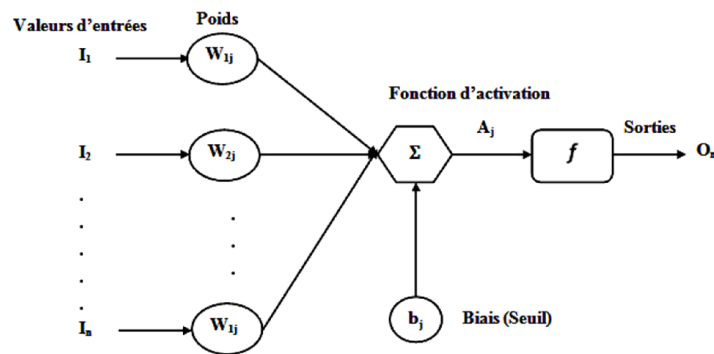


Fig. 2. Structure d'un neurone artificiel

La sortie O_n de l'intégrateur est définie par l'équation suivante :

$$O = W^T I - b \tag{3}$$

Le résultat de la somme pondérée représente le niveau d'activation du neurone. Le biais b est le seuil d'activation du neurone [12].

3.2 Développement des modèles de type PMC

Il existe un grand nombre de types de réseaux de neurones, dont chacun a des avantages et des inconvénients. Le réseau choisit dans notre cas est un réseau multicouches. Ce choix est fait pour la facilité et la rapidité de sa construction et encore par le fait que notre problème présente un nombre limité de variables d'entrées [13], [14]. La figure 3 illustre le Perceptron Multicouches dans le cas d'une seule couche d'entrée, de cachée et de sortie [15], [16].




Fig. 3. Exemple d'architecture d'un PMC à n variables d'entrée, n neurones pour la couche cachée et un neurone pour la couche de sorties

Le Perceptron Multicouches est composé d'un assemblage de neurones répartis sur L couches. La première couche correspondant au vecteur composé des données d'entrée, la dernière couche contient le vecteur de sortie composé des valeurs désirées et entre ces deux couches il existe un certain nombre de couches cachées. La complexité du réseau est en fonction du nombre de ces couches cachées et du nombre des neurones élémentaires composant chaque couche.

3.3 Développement des modèles de type RBF

Le réseau RBF fait partie des réseaux de neurones supervisés. Il est constitué de trois couches (figure 4): une couche d'entrée qui retransmet les entrées sans distorsion, une seule couche cachée qui contient les neurones RBF qui sont généralement des fonctions gaussiennes [17], [18], [19] et une couche de sortie dont les neurones sont généralement animés par une fonction d'activation linéaire.

Chaque couche est complètement connectée à la suivante et il n'y a pas de connexions à l'intérieur d'une même couche. La différence fondamentale par rapport au Perceptron est que le réseau de neurones de type RBF permet d'introduire une contrainte de couverture de la zone d'activation du neurone. Il devient alors possible d'apporter au réseau de neurones, au moment de sa conception, de l'information sur le système considéré. Comme un PMC, un RBF peut être utilisé dans la prédiction, l'identification, la classification ..., mais les réseaux RBF diffèrent des réseaux PMC, du fait que les fonctions d'activation des nœuds de la couche cachée sont des fonctions gaussiennes.

Le modèle de réseau RBF est caractérisé par quatre paramètres principaux, qui doivent être réglés, lors de l'étape de construction du réseau. Toute modification d'un de ces paramètres entraîne directement un changement du comportement du réseau. Ces paramètres sont :

- Le nombre de neurones RBF dans l'unique couche cachée ou le nombre des gaussiennes,
- La position des centres des gaussiennes de chacun des neurones.
- La largeur de ces gaussiennes.
- Le poids des connexions entre les neurones RBF et le(s) neurone(s) de sortie.




Fig. 4. Structure typique d'un réseau de neurones de type RBF

La couche cachée contient les n nœuds, qui appliquent une transformation non linéaire sur les variables d'entrée. Plus spécifiquement, chaque nœuds n a un centre C_n , où C_n est un vecteur dont la dimension est égale au nombre d'entrées.

Pour chaque nouveau vecteur d'entrée $I = [I_1, I_2, \dots, I_n]$, la norme de la distance euclidienne entre le vecteur d'entrée et le centre de nœuds est calculée comme suit [20], [21] :

$$v_n(I) = \|C_n - I\| = \sqrt{\sum_{i=1}^n (I_i - C_{n,i})^2} \tag{4}$$

Le rendement (sortie) des nœuds de la couche cachée est déterminé par une fonction d'activation non linéaire de type gaussien :

$$f(v) = \exp\left(-\frac{v^2}{\sigma^2}\right) \tag{5}$$

Avec σ est l'écart-type de la fonction d'activation. Une règle empirique consiste à prendre :

$$\sigma_n = \left(\frac{d_n}{\sqrt{2M}} \right) \tag{6}$$

Où d_n est la distance maximale entre le centre n et les autres centres et M présente le nombre total des centres de la couche cachée.

Ainsi, le rendement du nœuds j de la couche cachée est donné par :

$$Z_j = f(v_j) \tag{7}$$

Un ensemble de poids synaptique $W_j, j = 1, 2, \dots, j$ est appliqué aux raccordements entre la couche cachée et la couche de rendement. Les nœuds dans la couche de rendement servent seulement comme unités d'addition, qui produisent le rendement final du réseau. La sortie de la couche de rendement sera donnée comme suit :

$$O = f \left(\sum_{i=1}^n W_j Z_j + b_j \right) \tag{8}$$

Avec $f(n)=n$: Fonction linéaire

L'ensemble des poids synaptiques qui existent entre la couche cachée et la couche de rendement est calculé en fonction du vecteur cible, $O = [O_1, O_2, \dots, O_n]$ qui est donné par [22], [23] :

$$W = \text{inv} (Z^T Z) Z^T Y^T \tag{9}$$

Avec inv : Inverse

A travers les formules mathématiques citées précédemment, nous avons présenté la topologie à suivre pour le développement du réseau neuronal RBF [24], [25], [26], [27], que nous appliquerons par la suite pour la prédiction du taux d'humidité.

4 RESULTATS ET DISCUSSION

4.1 Réseau de neurones de type PMC

Dans le cadre de ce travail, nous avons utilisé les réseaux de neurones non récurrents de type PMC. Le choix d'exploiter un type de réseaux de neurones par rapport à un autre n'est pas arbitraire, mais repose sur les fondements qu'exige le problème en question. Sachant que chaque type de réseaux, en termes d'apprentissage, est conseillé pour une application donnée. Nous avons opté donc pour le PMC puisqu'il répond aux spécificités du problème de prédiction. Ce réseau apporte des résultats très significatifs et le taux de précision de la prédiction étant meilleur.

Pour déterminer l'architecture du réseau à utiliser, nous avons varié le nombre de couche cachée, le nombre de neurones dans une couche cachée, les fonctions de transfert, le nombre d'itération et le pas d'apprentissage [26]. Pour cela nous avons divisé aléatoirement notre base de données en trois parties : 60% pour l'apprentissage, 20% pour le test et 20% pour la validation.

Dans le tableau, 1 nous avons présenté les calculs des MSE et R pour une, deux, trois et quatre couches cachées et nous avons remarqué que l'augmentation du nombre des couches cachées augmente la charge des calculs sans aucun gain de performance. Nous pouvons donc, affirmer que l'utilisation d'une seule couche cachée est meilleur pour le modèle de type PMC.

Table 1. Performances du système en fonction du nombre de couches cachées

Nombre de couches cachées	MSE (10^{-5})	R
1	3,6	0,97
2	5,39	0,96
3	5,71	0,94
4	40,41	0,39

Par ailleurs, signalons que nous avons choisi d'utiliser, pour l'apprentissage l'algorithme de Levenberg-Marquardt (LM) qui repose sur une méthode standard pour l'optimisation de l'erreur quadratique due à ses propriétés de convergence rapide et de robustesse. La méthode de cet algorithme s'appuie sur les techniques des moindres carrés non-linéaires et de l'algorithme de Gauss-Newton à voisinage restreint.

La principale motivation du choix de l'algorithme de Levenberg-Marquardt (LM) repose sur les avantages suivants :

- Facilité des modifications des critères de convergence,
- Interprétabilité des critères de convergence,
- Facilité de récupérer les variances des estimations,
- Rapidité de la convergence vers un minimum.
- Pour déterminer le modèle de type PMC, nous avons changé le nombre de neurones dans la couche cachée ainsi que les couples de fonctions de transfert. Les performances ont été évaluées grâce à l'erreur quadratique moyenne et le coefficient de corrélation. Les résultats obtenus sont illustrés dans les figures (5 et 6) et le tableau 2.

D'après ces résultats (figures 5 et 6, et le tableau 2) nous notons que:

- le couple de fonctions de transfert (Tansig -Tansig) a donné une erreur quadratique moyenne de $8,5 \times 10^{-5}$, avec un réseau d'architecture [7-8-1]. Avec cette configuration nous arrivons à une meilleure performance pour l'algorithme d'apprentissage LM. Cette performance a été rencontrée au bout de 50 itérations.
- Avec la fonction de transfert Tansig pour la couche cachée et la fonction Logsig pour la couche de sortie, la meilleure performance pour l'algorithme LM est obtenue avec le réseau de neurones qui a comme architecture [7-9-1]. Cette configuration a enregistré une erreur quadratique moyenne de 27×10^{-5} , au bout de trente itérations.
- Pour l'algorithme d'apprentissage LM, la meilleure performance est obtenue avec un réseau de neurones d'architecture [7-5-1], avec la fonction Tansig comme fonctions de transfert pour la couche cachée et la fonction purelin pour la couche de sortie, Avec 5 neurones cachés, l'erreur quadratique moyenne converge vers le minimum d'erreur ($MSE=1,5 \times 10^{-5}$).
- Pour le couple de fonctions de transfert (Logsig-Logsig), le minimum de l'erreur quadratique moyenne, a été obtenu avec un réseau d'architecture [7-10-1].
- Nous avons obtenu les meilleurs résultats pour ($MSE=7,8 \times 10^{-5}$) avec un réseau de neurones d'architecture [7-9-1] et qui a comme couple de fonctions d'activations (Logsig-Tansig). Ce couple est de même configuration neuronal que le couple de transfert (Tansig-Logsig).
- L'architecture [7-11-1] avec une fonction Logsig pour la couche d'entrée et une fonction Purelin pour la couche de sortie, a donné les meilleures performances pour une valeur minimale de l'erreur quadratique moyenne égale $7,8 \times 10^{-5}$.

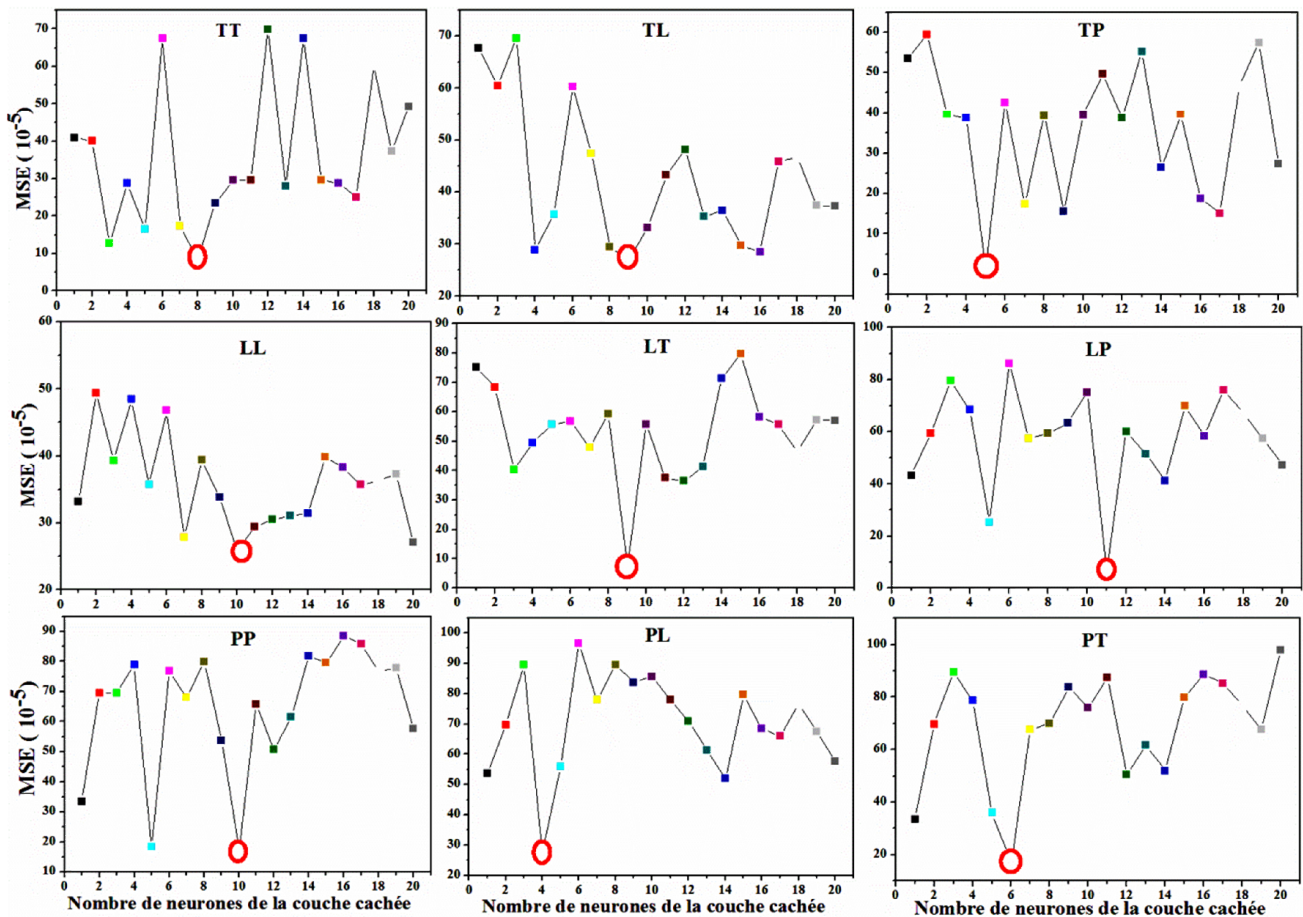


Fig. 5. Variation du MSE en fonction du nombre de neurones de la couche cachée pour l’algorithme d’apprentissage LM et pour différents couples de fonctions de transfert

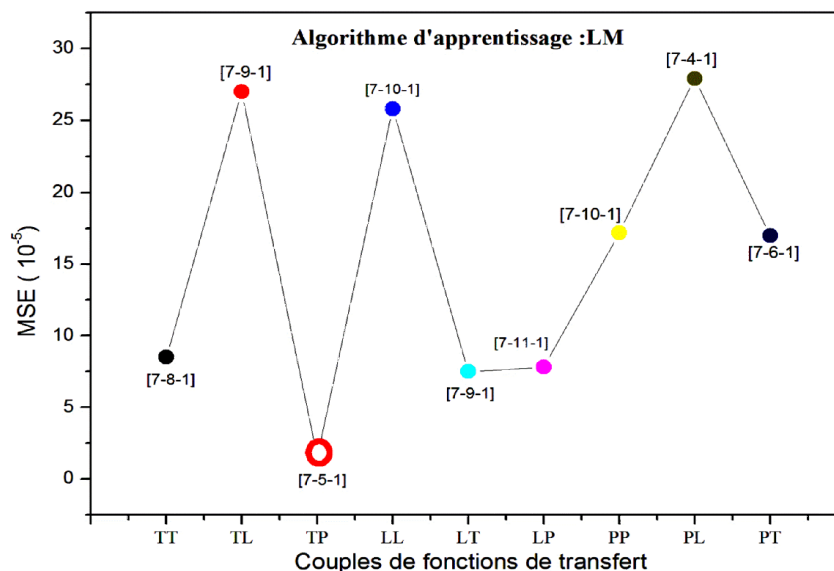


Fig. 6. Variation du MSE en fonction des couples de fonctions de transfert pour l’algorithme d’apprentissage LM

Désignations des couples de fonctions de transfert :

- | | | |
|-----------------------------|-----------------------------|----------------------------|
| TT: Tansig-Tansig; | TL: Tansig-Logsig; | TP: Tansig-Purelin; |
| LL: Logsig –Logsig; | LT: Logsig-Tansig; | LP: Logsig-Purelin; |
| PP: Purelin-Purelin; | PL: Purelin- Logsig; | PT: Purelin-Tansig. |

- Pour la combinaison de fonctions de transfert Purelin-Purelin le minimum de l'erreur quadratique moyenne est égal à $17,2 \times 10^{-5}$. Ce minimum est obtenu pour la configuration de réseau [7-10-1].
- L'architecture [7-4-1] avec une fonction Purelin pour la couche d'entrée et une fonction Logsig pour la couche de sortie, a donné la meilleure performance pour l'algorithme Levenberg-Marquardt, avec $MSE = 27,9 \times 10^{-5}$.
- Pour le couple de fonctions de transfert (Purelin-Tansig), le minimum de l'erreur quadratique moyenne est égal 17×10^{-5} , obtenu pour le réseau d'architecture [7-6-1] et pour quatre vingt itérations.
- L'algorithme LM converge avec le minimum du nombre d'itérations, 27 itération pour le couple de fonctions de transfert Tansig-Purelin et 90 représente la valeur maximale d'itération pour les combinaisons de fonctions de transfert Purelin-Tansig, cet algorithme est réputé très performant dans l'approximation des fonctions surtout quand le réseau contient moins d'une centaine de poids, surtout quand la taille du réseau est assez grande.

Table 2. Meilleures performances de LM obtenues pour chaque couples de fonctions de transfert

Couche cachée	Couche de sortie	Désignations	MSE (10^{-5})	Architecture	Nombre d'itérations
Tansig	Tansig	TT	8,50	[7-8-1]	50
Tansig	Logsig	TL	27,00	[7-9-1]	30
Tansig	Purelin	TP	1,50	[7-5-1]	27
Logsig	Logsig	LL	25,80	[7-10-1]	60
Logsig	Tansig	LT	7,50	[7-9-1]	30
Logsig	Purelin	LP	7,80	[7-11-1]	30
Purelin	Purelin	PP	17,20	[7-10-1]	30
Purelin	Logsig	PL	27,90	[7-4-1]	60
Purelin	Tansig	PT	17,00	[7-6-1]	90

Par ailleurs, signalons que d'après ces résultats, nous pouvons affirmer que pour la prédiction du taux d'humidité le modèle le plus performant est celui qui utilise comme fonctions de transfert, la fonction Tansig dans la couche cachée et la fonction Purelin dans la couche de sortie, tout en utilisant un algorithme d'apprentissage LM, de type PMC de configuration [7-5-1] et renfermant trois couche (Figure 7) :

- 7 neurones dans la couche d'entrée, représentant les variables météorologiques indépendantes ;
- 5 neurones dans la couche cachée, déterminés par les des indicateurs statistiques,
- Un seul neurone de la couche de sortie, qui représente le taux d'humidité.

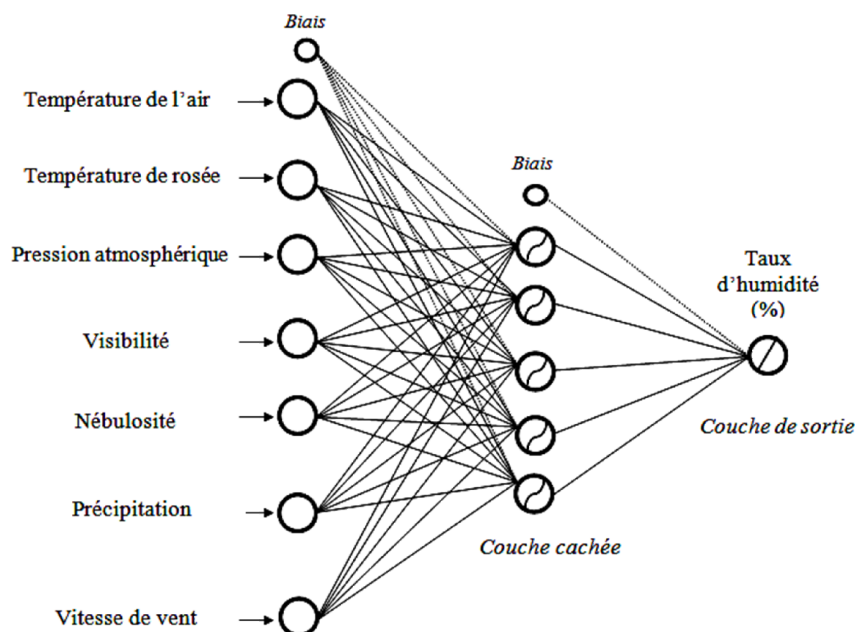


Fig. 7. Architecture du réseau de neurones à trois couches de configuration [7-5-1] développée dans cette étude

4.2 Réseau de neurones de type RBF :

Le réseau de neurone artificiel RBF se compose d'une couche d'entrée contenant sept neurones, d'une couche cachée et d'une couche de sortie contenant un seul neurone.

Les variables d'entrées se composent de sept vecteurs $I_1, I_2, I_3, \dots, I_7$, indépendants et normalisés entre -1 et 1 qui sont: la température de l'air, la température du point rosée, la pression atmosphérique, le vent, la pluie, la nébulosité et la visibilité.

Pour le développement du réseau RBF, nous calculons le centre gaussien de chaque vecteur : $C_1, C_2, C_3, \dots, C_7$ par l'utilisation de la moyenne arithmétique (Tableau 3), ainsi que la distance euclidienne entre les sept vecteurs et leur centre. Cette distance euclidienne est présentée à la couche cachée, pour être transformé en employant une fonction gaussienne.

Table 3. Calcul du centre gaussien pour chaque variable météorologique

Variable météorologique	Centres gaussien
Température de l'air (T_a)	18,82 (°C)
Température rosée (T_r)	11,78 (°C)
Pression atmosphérique (P_a)	1016,57(hPa)
Vitesse du vent (V)	10,56 (km/h)
Précipitations (Pr)	1,23(mm)
Nébulosité (Néb)	3,12(Octas)
Visibilité (Vis)	13,62(km)

La sortie de chaque neurone de la couche cachée sera amplifié par les poids W_i . Ces derniers ont été calculés par l'équation de pseudo-inverse, puis rajoutés au biais b_j de la couche de sortie et transformés enfin par une fonction linéaire. Nous obtenons alors le modèle du réseau RBF, tout en fixant les poids et les biais relevés dans la phase d'apprentissage. La

partie test consiste à valider l'architecture neuronale RBF de configuration [7-5-1] en jugeant sa capacité de prédiction. Nous avons par ailleurs comparé les performances des modèles statistiques neuronaux PMC et RBF.

Dans le tableau 4, nous donnons les moyennes des taux de prédiction relevés lors des phases d'apprentissages, de validation et de tests pour les modèles des réseaux neuronaux RBF et PMC.

Cette comparaison a pu mettre en évidence le fait que le modèle PMC est celui qui présente les meilleures performances. Bien qu'en terme de corrélation les trois phases soient identiques pour PMC. La part d'information apportée par chacun des modèles sur les observations réelles est également supérieure pour le modèle PMC, avec un coefficient de corrélation de 97%, et de 72% pour le modèle neuronal RBF (Tableau 4).

Table 4. Taux de prédiction moyens obtenus par les réseaux RBF, PMC

Réseaux	RBF	PMC
Taux d'apprentissage moyens (%)	73	97
Taux de validation moyens (%)	70	97
Taux de test moyens (%)	72	97

Avec les réseaux de neurones de type PMC, les modèles ont des coefficients de corrélation presque égal à l'unité ($R \sim 1$), Ceci montre qu'il y a un grand rapprochement entre les valeurs mesurées et celles simulées par le modèle PMC développé dans le cadre de ce travail. Ce modèle est peut donc être considéré comme un outil d'une grande efficacité dans le domaine de l'étude de la prévision du taux d'humidité de la zone de Chefchaouen.

Par l'étude des réseaux PMC et RBF, nous permettons de dégager les points suivants: les résultats obtenus par les deux modèles neuronaux sont satisfaisants, les taux d'apprentissage fournis par le PMC sont souvent les meilleurs, mais ses performances dépendent de l'initialisation des poids. La phase d'apprentissage du réseau PMC est plus rapide que celle de modèle neuronal RBF et il converge pour un nombre réduit d'itérations par rapport au réseau RBF. Par contre l'apprentissage du réseau RBF est simple, Ceci est en accord avec les résultats de quelques études plus récentes qui ont démontré que les modèles de type PMC sont plus performants comparativement à ceux établis par les modèles de type RBF [28], [29], [30].

5 Conclusion

Nous avons montré lors de cette étude, les performances de la méthode de prédiction par les réseaux de neurones en utilisant les réseaux PMC et RBF pour prédire l'humidité relative de la zone de Chefchaouen.

les résultats obtenus par l'ensemble des modèles sont satisfaisants; les taux d'apprentissage fournis par le PMC sont les plus meilleurs mais ses performances dépendent de l'initialisation des poids. Les taux de test du réseau PMC sont les plus meilleurs que ceux des autres réseaux neuronaux RBF, d'où le réseau PMC a bien généralisé les nouvelles données. La phase d'apprentissage du réseau PMC est plus rapide que celle des réseaux neuronaux à fonction de base radiale et il converge pour un nombre réduit d'itérations par rapport aux réseaux RBF.

L'utilisation de ces modèles neuronaux dans le domaine de la prédiction s'est avérée intéressante et encourageante, pour cela nous envisageons l'application d'une autre base de donnée plus élargie et aussi l'utilisation d'autres techniques surtout pour mieux améliorer le taux d'apprentissage du réseau RBF.

Il est à signaler que notre étude nous a permis d'affirmer que pour la prédiction du taux d'humidité le modèle le plus performant est celui qui utilise comme fonctions de transfert, la fonction Tansig dans la couche cachée et la fonction Purelin dans la couche de sortie, tout en utilisant un algorithme d'apprentissage Levenberg-Marquardt, de type PMC de configuration [7-5-1] et renfermant trois couche.

REFERENCES

- [1] S. Abdelli, K. Nouira, A. Trabelsi, "Prévision du NO₂ en utilisant la méthode du réseau de neurones," *Business and Economic Statistics Modeling Laboratory Institut Supérieur de Gestion de Tunis*, pp. 129-140, 2012.
- [2] N. Cheggaga, F. Youcef Ettoumi, "Estimation du potentiel éolien," *Revue des Energies Renouvelables*, pp. 99 – 105, 2010.
- [3] A. Abdallaoui, H. El Badaoui, "Prédiction des teneurs en métaux lourds des sédiments à partir de leurs caractéristiques physico-chimiques," *Journal Physical and Chemical News*, vol. 58, pp. 90-97, 2011.
- [4] M. Bélanger, N. El-Jabi, D. Caissie, F. Ashkar, J. M. Ribí, "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*, vol. 18, pp. 403-421, 2005.
- [5] H. El Badaoui, A. Abdallaoui, I. Manssouri, H. Ousmana, "The prediction of moisture through the use of neural networks MLP type," *Journal of Computer Engineering*, vol. 11, pp. 66-74, 2013.
- [6] W. Wongseeree, N. Chaiyaratana, "Thalassaemia classification by neural networks and genetic programming," vol. 177, pp. 771-786, 2006.
- [7] I. Maqsood, M. Khan, A. Abraham, "An ensemble of neural networks for weather forecasting," *Neural Comput. And Appl*, vol. 13, pp. 112-122, 2004.
- [8] M. Khan, C. Ondrusek, "Short-term Electric demand prognosis using artificial neural networks," *Electr. Eng*, vol. 51, pp. 296-300, 2000.
- [9] H. Vassiliki Mantzari, H. Dimitrios Mantzaris, "Solar radiation: Cloudiness forecasting using a soft computing approach," *Artificial Intelligence Research*, vol. 2, pp. 69-80, 2013.
- [10] D. Mantzaris, G. Anastassopoulos, "Intelligent prediction of vesicoureteral reflux disease," *WSEAS Trans. Syst*, vol. 4, pp. 1440-1449, 2005.
- [11] S. Baboo, I. Shereef, "An efficient weather forecasting system using artificial neural network," *Int. J. Environ. Sci*, vol. 1, pp. 321-326, 2010.
- [12] S. Chabaa, "Identification des systèmes non linéairement utilisant les techniques d'intelligence artificielles et les bases de fonctions de la guerre pour la modélisation des données du trafic dans les réseaux internet," *Thèse de Doctorat*, Université Cadi Ayyad, Faculté des Sciences Semlalia-Marrakech, 187p, 2011.
- [13] I. Manssouri, M. Manssouri, B. El Kihel, "Fault Detection by K-NN algorithm and MLP neuronal networks in distillation column," *Journal of information, Intelligence and knowledge*, vol. 3, pp.72-75, 2011.
- [14] R. Nayak, L. Jain, B. Ting, "Artificial neural networks in biomedical engineering: a review," *Proc. 1st Asian-Pacific Congr. Comput. Mech.*; pp. 887-892, 2001.
- [15] M. Vourkas, G. Papadourakis, "Effects of segmentation on the discrimination of three mental stages using ANN and different EEG signal representations," *Proc. 4th Int. Con. Neural Networks and Expert Syst*, pp. 65-68, 2001.
- [16] K. Papik, B. Molnar, "Application of neural networks in medicine - a review," *Med. Sci. Monit.* pp. 538-546, 1998.
- [17] D.S. Broomhead, D. Lowe, "Multivariate functional interpolation and adaptive networks," *Complex Systems*, vol. 2, pp. 321-355, 1988.
- [18] J. Moody, C.J. Darken., "Fast Learning in Network for Locally Tuned Processing Units," *Neural Computation*, vol. 1, pp. 281-294, 1989.
- [19] T. Poggio, F. Girosi, "Network for approximation and learning," *Proc. IEEE*, vol. 78, pp. 1481 -1497, 1990.
- [20] D. Johari, T. Khawa, "Artificial neural network based technique for lightning prediction," *5th Stud. Conf. Res. Dev., Malaysia*, 2007.
- [21] D. Samek, D. Manas, "Artificial neural networks in artificial time series prediction benchmark," *Int. J. Math. Models Methods in Appl. Sci*, vol. 5, pp. 1085-1093, 2011.
- [22] Y. Radhika, M. Shashi, "Atmospheric temperature prediction using support vector machines," *Int. J. Comput. Theor. Eng*, vol. 1, pp. 1793-8201, 2009.
- [23] D. Coury, E. Segatto, "Pattern recognition to distinguish magnetizing inrush from internal faults in power transformers," *WSEAS Trans. Syst*, vol. 3, pp. 1258-1264, 2004.
- [24] K. Xu, M. Xie, L. C. Tang, S. L. Ho, "Application of neural networks in forecasting engine systems reliability," *Applied Soft Computing*, vol. 2, pp. 255-268, 2003.
- [25] J. W. Park, G. K. Venayagamoorthy, R. G. Harley, "MLP/RBF Neural- Networks-Based Online Global Model Identification of Synchronous Generator," vol. 52, pp. 1685-1695, 2005.
- [26] K. T. Chen, C. H. Chou, S. H. Chang, Y. H. Liu, "Intelligent active vibration control in an isolation platform," *Applied Acoustics*, vol. 69, pp. 1063-1084, 2008.
- [27] A. Zouidi, A. Chaari, M. Stambouli, F. Fnaiech, "Nonlinear continuous time modeling of a high pressure mercury vapor discharge lamp using feed forward back-propagation neural networks," *IEEE, Yasmine Hammamet, Tunisia*, 2004.

- [28] S. Simani, C. Fantuzzi, "*Fault diagnosis in power plant using neural networks Information Sciences*," vol. 127, pp. 125-136, 2000.
- [29] I. Mansouri, Y. Chetouani, B. El Kihel, "Using Neural Networks for fault detection in a distillation column", *International Journal Computer Applications in Technology*, vol. 32, pp. 181–186, 2008.
- [30] F. Mrabti, H. Seridi, " Comparaison de méthodes de classification réseau RBF, MLP et RVFLNN," *Damascus University Journal*, vol. 25, pp. 119-129, 2009.