

UTILISATION DES RESEAUX DE NEURONES ARTIFICIELS DE TYPE RBF POUR LA MODELISATION DU REGIME NORMAL A POINT DE FONCTIONNEMENT VARIABLE D'UNE INSTALLATION INDUSTRIELLE

Bouchra Boudebbouz

Laboratoire de Mécanique, Mécatronique et Commande, ENSAM –
Université Moulay Ismail Meknès, Maroc

Imad Manssouri

Laboratoire de Mécanique, Mécatronique et Commande, ENSAM –
Université Moulay Ismail Meknès, Maroc

Ahmed Mouchtachi

Directeur de l'école nationale supérieure d'arts et métiers de Casablanca -
Université Hassan II Mohammedia Casablanca – Campus BEN M'SIK -
Maroc.

Tajeddine Manssouri

Laboratoire de Géo-Ingénierie et Environnement, Faculté des Sciences,
Université Moulay Ismail, Zitoune, Meknès- Maroc.

Bachir El kihel

Laboratoire de génie industriel et mécanique de production ENSA –
Université Moulay Ismail Oujda, Maroc

Abstract

This work presents the development of a mathematical model based on stochastic artificial neural networks type RBF (Radial Basis Function) for modeling the normal mode at a variable point of functioning of an industrial installation. The studied industrial facility is a distillation column of methylcyclohexane ($C_6H_{11}-CH_3$) from toluene-methylcyclohexane mixture ($C_6H_5-CH_3 / C_6H_{11}-CH_3$) which was defined in the mass composition by 23% in methylcyclohexane. Neuronal architecture proposed for the modeling of this system consists of an input layer containing seven neurons, a hidden layer containing nine neurons and an output layer having a single neuron. The hidden layer is activated by a Gaussian function whose center is determined by using the K-means algorithm; however the output layer is activated by a linear function. Regarding existing weight between the hidden

layer and the output layer, they are determined by the back-propagation algorithm of the error gradient. The RBF neural architecture type so determined was validated on a new database and has achieved better results compared to conventional methods.

Keywords: RBF neural networks, modeling, algorithm of K-means, distillation column, Back-propagation gradient

Résumé

Ce travail présente le développement d'un modèle mathématique stochastique basé sur les réseaux de neurones artificiels de type RBF (Radial Basis Function) pour la modélisation du régime normal d'une installation industrielle à point de fonctionnement variable.

L'installation industrielle étudiée est une colonne de distillation de méthylcyclohexane ($C_6H_{11}-CH_3$) à partir d'un mélange Toluène-méthylcyclohexane ($C_6H_5-CH_3/C_6H_{11}-CH_3$) dont on a défini la composition massique à 23% en méthylcyclohexane.

L'architecture neuronale proposée pour la modélisation de cette installation se compose d'une couche d'entrée contenant sept neurones, d'une couche cachée contenant neuf neurones et d'une couche de sortie contenant un seul neurone. La couche cachée est activée par une fonction gaussienne dont le centre est déterminé à l'aide de l'algorithme des K-means ; par contre, la couche de sortie est activée par une fonction linéaire. En ce qui concerne les poids existants entre la couche cachée et la couche de sortie, ils sont déterminés par l'algorithme de Rétro-propagation du gradient d'erreur.

L'architecture neuronale de type RBF ainsi déterminée a été validée sur une nouvelle base de données et a permis d'obtenir de meilleurs résultats par rapport aux méthodes classiques.

Mots clés: Réseaux de neurones RBF, Modélisation, Algorithme des K-moyennes, colonne de distillation, Rétro-propagation du gradient

Introduction

La modélisation du fonctionnement normal d'une unité industrielle est devenue une nécessité vitale qui permet à l'opérateur de détecter n'importe quelle avarie qui conduira à la modification du régime normal du système et causera par la suite une perturbation de son fonctionnement, cette situation engendre un manque de protection et de sécurité en plus d'une perte au niveau de la qualité requise.

La modélisation est indispensable pour la compréhension et l'analyse des phénomènes mis en jeu dans les systèmes industriels. La conduite de tels systèmes repose également sur l'utilisation de modèles. Ces derniers doivent

rendre compte de la structure et du comportement du système et permettre l'analyse de ses propriétés qualitatives et quantitatives.

Ces analyses conduisent à la définition des grandeurs caractérisant le processus, c'est-à-dire ses entrées, ses variables d'état, ses sorties, et aussi les perturbations, mesurables ou non, auxquelles il est soumis.

On trouve dans la littérature plusieurs méthodes de modélisation, parmi lesquelles on cite à titre d'exemple les méthodes basées sur les réseaux de neurones artificiels :

(Nohair, 2008) ont utilisé les réseaux de neurones pour prédire les changements dans un flux d'eau en fonction des variables climatiques telles que la température de l'air ambiant et la température de l'écoulement de l'eau reçue par le courant d'eau. Deux méthodes ont été utilisées: la première, de type itératif, utilise le jour j estimé pour prédire la valeur de la température de l'eau du jour $j+1$, et la deuxième méthode est beaucoup plus simple à mettre en œuvre, il s'agit d'estimer la température de tous les jours pris en une seule fois.

(Sharma, 2004) ont utilisé les réseaux de neurones feedforward pour la détection de six dysfonctionnements, dans une colonne de distillation de $\text{NH}_3\text{-H}_2\text{O}$. De ce point de vue, ils ont comparé deux architectures de réseaux: [6-4-6] et [3-4-6] et ont adopté la seconde structure [3-4-6] qui a permis de réduire le temps de calcul et de détecter les défauts en ligne.

(Chen, 2008) ont utilisé un système hybride pour la détection et le diagnostic des défauts, connu sous le nom de « système neuro-flou ». C'est un système qui combine les avantages de la logique floue et les réseaux de neurones. Chen et al. ont montré que la méthode proposée a permis de détecter et de diagnostiquer correctement les défauts les plus fréquents du circuit de chemin de fer dans une installation de test au laboratoire.

(Jian-Da, 2008) ont présenté une technique de diagnostic de défauts du moteur à combustion interne. La technique proposée est basée sur l'analyse des WPT (Wavelet Packet Transform) combinée avec les réseaux de neurones artificiels (ANN) pour détecter et classifier les défauts de fonctionnement dans un moteur à combustion interne dans divers régimes. La technique proposée du WPT présente de nombreux avantages en ce qui concerne CWT (Continuous Wavelet Transform) et DWT (Discrete Wavelet Transform), pour vérifier l'efficacité de GRNN (Generalized Regression Neural Network). Cette technique a été comparée à un réseau BPN (Back Propagation Networks). L'étude a montré que le réseau GRNN a été efficace pour diagnostiquer et classifier le fonctionnement d'un moteur à combustion interne dans divers régimes.

(Ertunc, 2008) ont établi une analyse comparative d'un condenseur à évaporation en utilisant les réseaux de neurones artificiels (ANN) et un système d'interface adaptatif neuro-flou (ANFIS). Les performances de

prédiction statistiques des deux modèles sont mesurées en termes de coefficient de corrélation, erreur relative moyenne, erreur quadratique moyenne et la fraction absolue de la variance. Bien que les prédictions des deux modèles aient donné une bonne performance statistique, les précisions de prédictions ANFIS étaient généralement supérieures à celles des ANN.

(Sanaye, 2011) ont appliqué les réseaux de neurones artificiels à la modélisation d'un compresseur à palettes rotatives. Le réseau de neurones artificiel (ANN) et le modèle de la régression non linéaire (NLREG) ont été utilisés pour prédire la performance du système du compresseur en prédisant les températures du débit massique de réfrigérant et la décharge de ce dernier. Trois critères, le coefficient de corrélation, l'erreur relative moyenne et l'erreur quadratique moyenne ont été appliqués pour la comparaison des résultats. La modélisation ANN a démontré une meilleure performance statistique que celle de la modélisation NLREG.

(Boudebouz, 2014) ont utilisé la régression linéaire multiple totale et les réseaux de neurones artificiels - Perceptron Multicouches pour la modélisation du système normal, au point de fonctionnement variable d'une colonne de distillation continue de Méthylcyclohexane, le modèle réalisé sur la base du réseau de neurones artificiels de type MLP a donné le meilleur résultat, l'architecture choisie du modèle [7-14-1] a donné un coefficient de détermination de 81,9% dans la phase de test et validation et une erreur quadratique moyenne de 0,12.

Génération du modèle

La structure typique d'un réseau de neurones RBF (Figure.1) se compose de trois couches à savoir: une couche d'entrée, une couche cachée et une couche de rendement. Chaque couche se compose d'un certain nombre de neurones (noeuds). Dans la couche d'entrée, les noeuds sont employés pour faire passer seulement les données d'entrée à la couche cachée. Aucun calcul n'est exécuté dans les noeuds de la couche d'entrée.




Figure.1 : Structure typique des réseaux RBF

La couche cachée contient les k noeuds, qui appliquent une transformation non linéaire sur les variables d'entrée. Plus spécifiquement, chaque noeud j a un centre c_j ; où c_j est un vecteur dont la dimension est égale au nombre d'entrées.

Pour chaque nouveau vecteur d'entrée $X = [x_1, x_2, \dots, x_N]$, la norme de la distance euclidienne entre le vecteur d'entrée et le centre de noeud est calculée comme suit :

$$v_j(X) = \|c_j - X\| = \sqrt{\sum_{i=1}^N (x_i - c_{j,i})^2} \quad [1]$$

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

$$f(v) = \exp\left(-\frac{v^2}{\sigma^2}\right) \quad [2]$$

Avec σ l'écart type de la fonction d'activation. Une règle empirique (Schobbens, 2000) consiste à prendre:

$$\sigma_j = \frac{1}{N\sqrt{8}} \sum_{i=1}^N \|x_i - c_j\| \quad [3]$$

Ainsi, la sortie du noeud j de la couche cachée est donnée par:

$$Z_j = f(v_j) \quad [4]$$

Un ensemble de poids synaptique w_j , $j = 1, 2, \dots, k$ est appliqué aux raccordements entre la couche cachée et la couche de rendement. Les noeuds 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:

$$y = L\left(\sum_{j=1}^{j=k} w_j Z_j + b_j\right) \quad [5]$$

Avec $L(n) = n$ fonction linéaire

Les poids synaptiques qui existent entre la couche cachée et la couche de sortie sont calculés par l'algorithme de rétro propagation du gradient de la manière suivante:

$$w_{j+1} = w_j - \alpha * err_j * \frac{d}{dZ_j} Z_j \quad [6]$$

Avec Z la matrice contenant différentes sorties des neurones de la couche cachée, α le taux d'apprentissage et err_j l'erreur commise entre le vecteur cible et le vecteur prédit.

Détermination des centres par l'algorithme des K-Means

La position des centres c_1, c_2, \dots, c_k des fonctions de base est également un paramètre à déterminer. Dans notre cas l'algorithme K-means est utilisé pour sélectionner un ensemble de centres. Le principe de cet algorithme consiste à fixer au préalable un nombre k de centres de classes. C'est-à-dire connaître a priori le nombre de classes. On commence par le choix aléatoire de k centres. Puis on calcule la distance de chaque élément de la base des données par rapport à chacun des centres. Par la suite on affecte l'élément à la classe du centre qui lui est le plus proche. Une fois, la base des données est balayée entièrement, on recalcule les nouveaux centres des classes. On répète les trois opérations de calcul de distance, d'affectation et de détermination des nouveaux centres jusqu'à satisfaction d'un critère d'arrêt. Le critère d'arrêt le plus utilisé consiste à arrêter le processus lorsque les changements des positions des centres deviennent insignifiants.

Cet algorithme vise à réduire au minimum une fonction objective, dans ce cas-là il s'agit d'une fonction erreur carrée.

$$j = \sum_{j=1}^K \sum_{i=1}^N \|x_i^{(j)} - c_j\|^2 \quad [7]$$



Figure.2 : Installation de distillation continue

Où $\|x_i^{(i)} - c_j\|$ est une mesure choisie de distance entre un point de repères $x_i^{(i)}$ et le centre c_j .

L'algorithme se compose des étapes suivantes :

- Placer les K points dans l'espace représenté par les objets. Ces points

représentent les centres initiaux des classes.

- Assigner chaque objet à la classe du centre le plus proche de lui.
- Quand tous les objets ont été assignés, recalculer les nouvelles positions des centres.
- Répéter les étapes 2 et 3 jusqu'à ce que les centres ne se déplacent plus.

Partie expérimentale

L'installation étudiée est une installation de distillation de Méthylcyclohexane à partir d'un mélange Toluène/méthylcyclohexane dont on a défini la composition massique à 23% de méthylcyclohexane.

Les principaux organes constituant l'installation de distillation continue sont la colonne à garnissage, le bouilleur, le condenseur en tête de colonne et la pompe doseuse. (Figure.2).

Description du fonctionnement de la colonne de distillation continue

Le mélange (toluène/méthylcyclohexane) est introduit à travers le plateau d'alimentation de la colonne, une partie de ce mélange est volatilisé alors que l'autre partie redescend dans le bouilleur avec le reflux venant de la tête de colonne.

La qualité du produit recueilli en tête de la colonne dépend du débit de reflux dont le taux varie à l'aide d'un clapet électromagnétique régulé par la température en tête de colonne, lorsque cette dernière est atteinte, le clapet s'ouvre, dans le cas inverse, il demeure fermé. Le condenseur ayant la surface d'échange 0,08m², est placé en tête de colonne pour condenser complètement les vapeurs.

Des échangeurs de chaleurs sont intégrés pour assurer un refroidissement soit du distillat soit du résidu.

Le système de préchauffe est constitué de trois sous ensemble de résistances chauffantes d'une puissance de 250 W chacune, avec en plus un capteur de niveau empêchant la mise en marche si le niveau dans le corps de verre est trop bas dans le bouilleur.

La pompe doseuse est constituée d'une membrane assurant l'aspiration du mélange à distiller et son refoulement vers le réservoir de préchauffe.

Le garnissage de la colonne de distillation continue favorise le transfert de la matière entre la phase vapeur et la phase liquide. Le type de garnissage choisi pour assurer ce rôle est MULTIKNIT inox 316 L, en plus, pour se rapprocher aux conditions adiabatiques, un calorifuge constitué de laine de verre est utilisé.

Pour le système de supervision, il est constitué du logiciel ETP200 et il a plusieurs fonctionnalités, il permet de modifier les paramètres d'entrée et de sortie du système, de suivre leur évolution et d'assurer la tendance de

groupe. La tendance de groupe permet de suivre l'évolution des mesures de chaque appareil lié à la régulation. Cette évolution peut être visualisée en temps réel ou en historique.

Détermination du mode normal de l'installation de distillation continue

Pour déterminer l'intervalle de travail, nous avons défini l'objectif d'obtenir un mélange riche en méthylcyclohexane, pour cela, et à partir du diagramme isobare liquide vapeur du mélange toluène/méthylcyclohexane, nous avons déterminé une plage de température [101,1°C ; 103,4°C] équivalente à un intervalle de titres de [0,48 ; 0,84] définissant le mode normal de fonctionnement et cela en utilisant le modèle de Wilson pour la modélisation du mélange (Figure.3). La définition de cette plage de température découle du fait que la purification de ce mélange binaire en industrie s'effectue dans cette gamme.

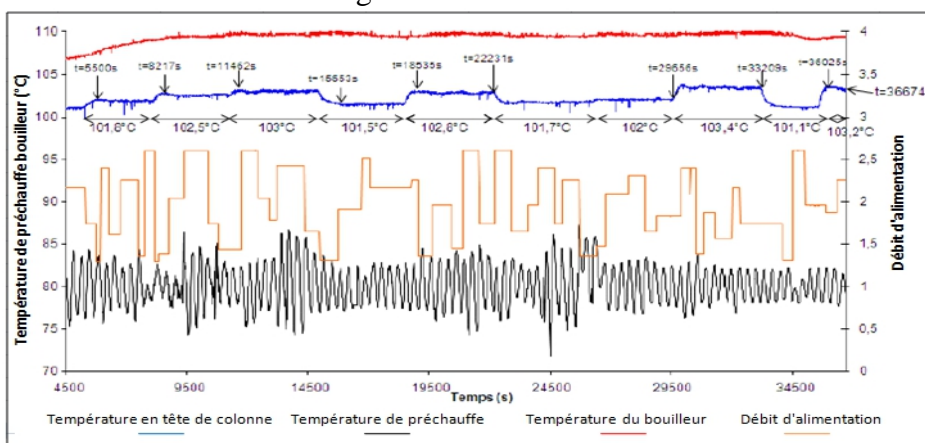


Figure.3 : Comportement normal de la colonne de distillation continue

Cette sélection a permis d'affecter une gamme pour chaque entrée (Figure.4) du système pour avoir une température constante à la sortie



Figure.4 : Détermination des entrées/sorties de la colonne de distillation

Résultats et discussions

La température en tête de colonne du distillat (Td) est modélisée en fonction des variables d'entrée du processus tels que : la puissance de chauffe (x_1), la puissance de préchauffe (x_2), le taux de reflux (x_3), le débit d'alimentation (x_4), les pertes de charges (x_5), la température de préchauffe (x_6) et la température du bouilleur (x_7), par un modèle neuronale de type RBF-BP vu sa capacité à identifier des relations complexes et non linéaires entre les entrées et les sorties des ensembles de données sans la nécessité de comprendre la nature des phénomènes [Ada 10].

De manière générale, les bases de données doivent subir un prétraitement afin d'être adaptées aux entrées et sorties des modèles mathématiques stochastiques. Un prétraitement courant consiste à effectuer une normalisation appropriée, qui tient compte de l'amplitude des valeurs acceptées par les modèles. On obtient une base de données normalisée entre 0,1 et 0,9.

La normalisation de chaque entrée x_i est donnée par la formule:

$$x_{i \text{ new}}^k = 0,8 * \frac{x_{i \text{ old}}^k - \min(x_i)}{\max(x_i) - \min(x_i)} + 0,1 \quad [8]$$

Le réseau de neurones artificiels de type RBF est composé d'une couche d'entrée contenant sept neurones, d'une couche cachée contenant neuf neurones et d'une couche de sortie contenant un seul neurone.

La couche cachée est activée par une fonction gaussienne dont le centre est déterminé à l'aide de l'algorithme des K-means ; par contre, la couche de sortie est activée par une fonction linéaire. En ce qui concerne les poids existants entre la couche cachée et la couche de sortie, ils sont déterminés par l'algorithme de Rétro-propagation du gradient d'erreur.

Les figures 5 et 6 représentant respectivement RMSE et R^2 calculés pour les différents nombres de neurones de la couche cachée, donnent la possibilité de choisir 9 neurones pour cette couche. Nous obtenons alors l'architecture [7-9-1] comme meilleure configuration du réseau de neurones RBF.




Figure.5 : Erreur quadratique moyenne

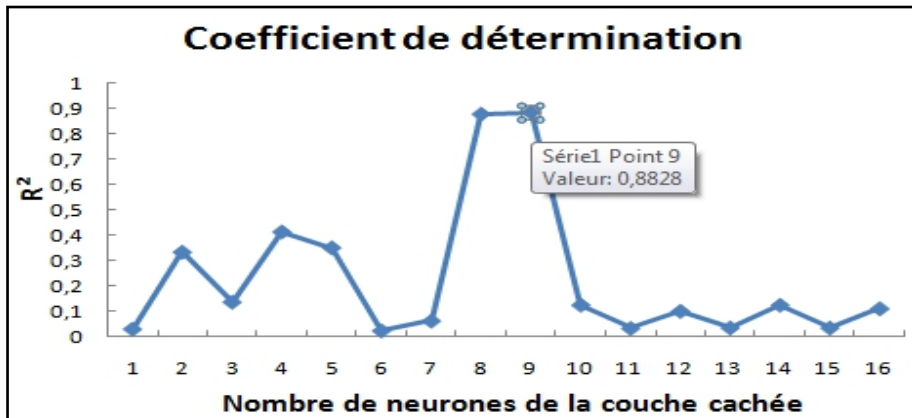
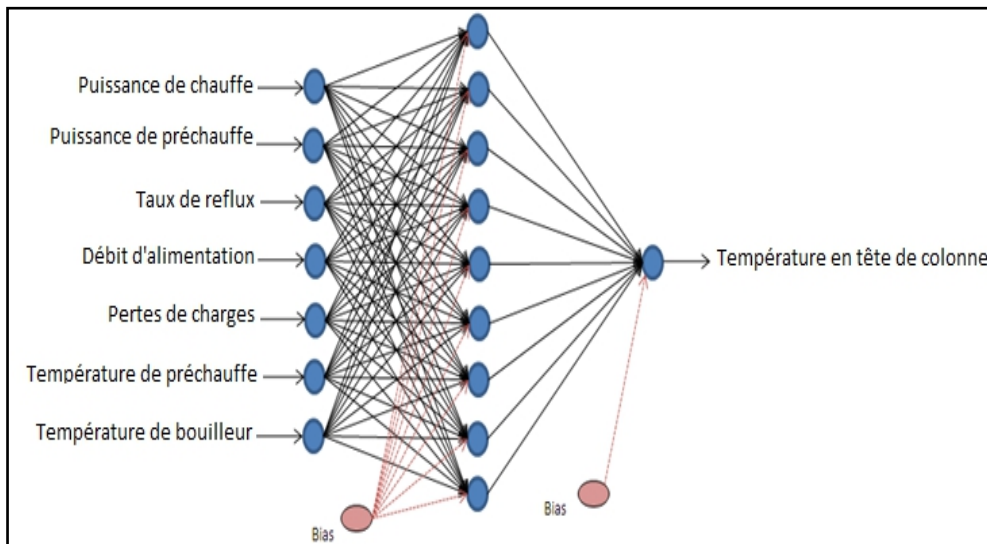


Figure.6 : Coefficient de détermination R^2

Apprentissage et validation

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



(Figure.7).

Figure.7 : Réseau de neurones RBF – Architecture [7-9-1]

La base d'apprentissage du réseau neuronal est constituée de 577 échantillons c'est à dire 60% de la totalité des données. Les poids et les biais du réseau ont été réajustés à l'aide de l'algorithme de Rétro-propagation du gradient d'erreur.

Une fois que l'architecture, les poids et les biais du réseau neuronal

ont été fixés il faut savoir si ce modèle neuronal est susceptible d’être généralisé.

La validation de l’architecture neuronale [7-9-1] consiste donc à juger sa capacité de prédiction de la température en tête de colonne en utilisant les poids et les biais calculés durant l’apprentissage, pour les appliquer à une autre base de données tests composés de 384 échantillons c’est-à-dire 40% de la totalité des données. (Figure.8).




Figure.8 : Résultats de la prédiction de la température dans la tête de la colonne RNA-RBF [7-9-1]

Le modèle de RNA-RBF [7-9-1] a donné un coefficient de détermination pour la phase de test et de validation de 0.8828 et une erreur quadratique moyenne de 0,0455.

La moyenne des valeurs absolues des résidus (Résidu = Target – Output) est de l’ordre de 0,17. (Figure.9)

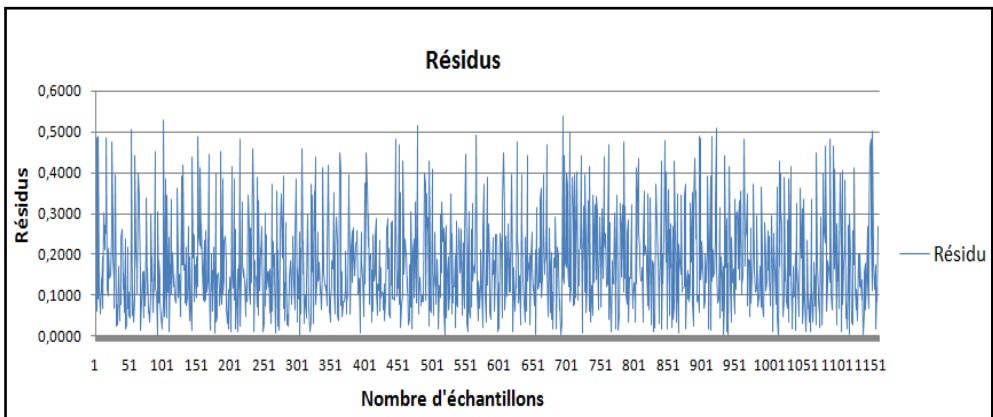


Figure.9 : Graphe des résidus

Conclusion:

Dans cette étude, L'apprentissage du modèle neuronal RBF développé a été effectué en déterminant les poids et les biais à l'aide de l'algorithme de Rétro-propagation du gradient d'erreur. Pour construire la base d'apprentissage, nous nous sommes basés seulement sur les données en régime normal de notre système de distillation.

L'architecture retenue de ce modèle est l'architecture ANN-RBF [7-9-1] qui a permis d'obtenir un coefficient de détermination de **88.28%** et une erreur quadratique moyenne de **0.0455**, ce qui représente le meilleur résultat.

Dans une étude faite précédemment [Bou 14], nous avons utilisé deux modèles à savoir la régression linéaire multiple totale et les réseaux de neurones artificiels - Perceptron Multicouches pour la modélisation du même système, le modèle retenu était le modèle ANN-MLP qui a donné un coefficient de détermination de **81,9%** dans la phase de test et de validation et une erreur quadratique moyenne de **0,12**.

En comparaison avec cette étude, nous concluons que le modèle ANN-RBF-BP a donné un résultat meilleur que celui du modèle ANN-MLP.

References:

- M Nohair, A St-Hilaire et T. B Ouarda, «Schobbens Utilisation de réseaux de neurones et de la régularisation bayésienne en modélisation de la température de l'eau en rivière ». *Revue des sciences de l'eau*. Journal of Water Science, vol. 21, n° 3, p. 373-382, 2008.
- Sharma R., Singh K., Singhal D. and Ghoshd R. «Neural network applications for detecting process faults in packed towers», *Chemical Engineering and Processing*, Vol. 43, pp.841–847, 2004.
- Chen J. Roberts C. and Weston P. «Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems». *Control Engineering Practice*, Volume 16, Issue 5, pp: 585-596, 2008.
- Jian-Da Wu, C.H. «An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network». *Expert Systems with Applications*, In Press, Corrected Proof, 2008.
- H. Metin Ertunc, Murat Hosoz, «Comparative analysis of an evaporative condenser using Artificial neural network and adaptive neuro-fuzzy - inference system»- *International journal of refrigeration* 31, pages 1426 – 1436, 2008.
- Sanaye S, Dehghandokht M, Mohammadbeigi H, Bahrami S, - «Modeling of rotary vane compressor applying artificial neural network» *International journal of refrigeration* 34, pages 764 – 772, 2011.
- Boudebouz B, Manssouri I, Mouchtachi A, El Kihel B «Using the Total Multiple Linear Regression and Artificial Neurons Network-Multi Layer

Perceptron for modelling the normal system, at variable point of functioning of a continuous distillation column methylcyclohexane» - *International Journal of Science and Research (IJSR)* ISSN: 2319-7064 Volume 3 Issue 6, June 2014.

Schobbens, P.Y, *Cours d'intelligence artificielle: Application aux systèmes d'aide à la décision*. Facultés Universitaires Notre Dame de la paix, Belgique, 2000.

Adamowski J., Sun K. «Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds». *Journal of Hydrology*, Vol. 390, No.1, p 85–91, 2010.