

Utilisation d'un modèle hybride basé sur les réseaux de neurones artificiels-PMC couplés à la décomposition en ondelettes pour la modélisation du régime normale à point de fonctionnement variable. Cas d'une installation industrielle

Bouchra BOUDEBBOUZ

Laboratoire de Mécanique, Mécatronique et Commande,
École Nationale Supérieure d'Arts et Métiers, Université
Moulay Ismail, BP 4042, 50000
Meknès, Maroc
bouchra.boudebbouz@gmail.com

Ahmed MOUCHTACHI

Directeur de l'École Nationale
Supérieure d'Arts et Métiers, Université Hassan II
Mohammedia-Casablanca
Casablanca, Maroc
ahmedmouchtachi@yahoo.fr

Imad MANSSOURI

Laboratoire de Mécanique, Mécatronique et Commande,
École Nationale Supérieure d'Arts et Métiers, Université
Moulay Ismail, BP 4042, 50000
Meknès, Maroc
imade_mansouri@yahoo.fr

Tajeddine MANSSOURI

Laboratoire de Géo-Ingénierie et Environnement,
Faculté des Sciences, Université Moulay Ismail, B.P. 11201,
Zitoune
Meknès, Maroc
t.manssouri@yahoo.fr

Résumé — La complexité d'un système industriel nécessite que ce dernier soit modélisé de la manière la plus réaliste possible. Ceci permettra une meilleure surveillance du processus et par la suite la détection de toute perturbation pouvant engendrer une instabilité et un dysfonctionnement du système.

Le présent article, décrit des méthodes de modélisation basées sur le couplage de la transformée en ondelettes stationnaire (Stationary Wavelet Transform SWT) et les réseaux de neurones artificiels (Artificial Neural Networks ANN) de type perceptron multi-couches (Multi Layer Perceptron MLP) pour la modélisation du régime normale à point de fonctionnement variable d'une unité industrielle.

L'unité 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.

La base de données qui servira, d'une part comme base d'apprentissage et d'autre part comme base de test et validation, des modèles SWT-ANN-MLP (Stationary Wavelet Transform-Artificial Neural Networks- Multi-layer perceptron) est constituée par les variables d'entrées qui sont : la puissance de chauffe, la puissance de préchauffe, le taux de reflux, le débit d'alimentation, les pertes de charge, la température de préchauffe et la température de bouilleur et la variable de sortie qui est la température en tête de colonne. Trois configurations

ont été proposées dans cette étude et en calculant les paramètres de performance, un seul modèle a été retenu SWT-ANN-MLP d'architecture neuronale [7-17-1] qui a donné un coefficient de détermination $R^2=0.86$, un Coefficient d'efficacité NSE = 0.853 et une erreur quadratique moyenne MSE = 0.009.

Cette méthode hybride de modélisation basée sur la décomposition en ondelettes stationnaire et les réseaux de neurones artificiels de type Perceptron multi-couches a montré sa robustesse par rapport à d'autres méthodes de modélisation appliquées sur la même installation industrielle à savoir l'utilisation des réseaux de neurones artificiels à fonction de base radial (RBF) et les réseaux de neurones artificiels de type Perceptron Multi-couches.

Mots clés — Modélisation; Décomposition en Ondelettes; Réseau de Neurones Artificiel; perceptron multi-couches; Installation Industrielle; coefficient Nash-Sutcliffe efficiency; coefficient de détermination.

Keywords — Modeling; Wavelet decomposition; Artificial Neural Network, Multilayer Perceptron; Industrial facility; Nash-Sutcliffe efficiency coefficient; coefficient of determination.

I. INTRODUCTION

Pour accompagner l'évolution rapide des nouvelles technologies dans les différents domaines, les installations industrielles deviennent de plus en plus complexes et leur modélisation affronte différentes contraintes pour arriver à un résultat représentatif du système concerné.

Un système est dit complexe quand sa décomposition fait apparaître un grand nombre de sous-systèmes ou des sous-systèmes de natures trop différentes. Ces deux principales sources de complexité d'un système qui sont sa taille et son hétérogénéité sont le plus souvent présentes en même temps dans un système complexe. La modélisation du fonctionnement normal d'une unité industrielle est devenue une nécessité primordiale pour détecter toute anomalie conduisant à la modification du régime normal d'un système et causera la perturbation de son fonctionnement.

L'objectif de cet article est la description des méthodes de modélisation basées sur le couplage de la transformée en ondelettes stationnaire (Stationary Wavelet Transform SWT) et les réseaux de neurones artificiels (Artificial Neural Networks ANN) de type perceptron multi-couches (Multi Layer Perceptron MLP) pour la modélisation du régime normale à point de fonctionnement variable d'une unité industrielle.

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 :

[1] ont proposé une nouvelle approche au réseau de neurones d'ondelettes floues pour l'algorithme de modélisation et d'optimisation. La logique floue est combinée avec le réseau de neurones d'ondelettes qui permet une partition logique floue de l'espace d'entrée en différents sous-espaces à base d'ondelettes. La méthode hybride proposée trouve la solution optimale et obtient une meilleure performance que les autres modèles, malgré l'existence de moins de règles et un plus petit nombre de paramètres.

[2] ont effectué la prévision de la sécheresse (valeurs SPI) pour des périodes de 1, 3 et 6 mois pour la région Inaouène au nord du Maroc, et cela en utilisant des réseaux de neurones artificiels (RNA) de type Perceptron Multi-couches (PMC) couplés à l'analyse en ondelettes stationnaire (SWT). Tout d'abord, la série de valeurs de l'indice de précipitation standardisé (SPI) sont faites pour des échelles de temps de 3, 6 et 12 mois sur la base de valeurs de pluviométrie moyenne mensuelle. Ensuite, la décomposition en ondelettes stationnaire a été réalisée pour la série des précipitations mensuelles, série NAO et séries des valeurs SPI déjà calculés. Et puis, les modèles hybrides sont développés sur la base de réseaux de neurones artificiels en les intégrant en tant que sous-séries d'entrée établies par le SWT. Les résultats indiquent que l'analyse en ondelettes permet un prétraitement efficace des ensembles de données et contribue ainsi à améliorer la performance des modèles traditionnels RNA pour la prévision de la sécheresse.

[3] 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.

[4] Dans leur étude, des signaux de vibration sont décomposés par Discrete Wavelet Transform et les caractéristiques sont extraites du coefficient d'ondelettes dominante pour trois conditions de roulement à savoir Normal, défaut sur la bague intérieure et défaut sur la bague extérieure. Les caractéristiques obtenues à partir de signaux bruts et débruités de vibrations, sont utilisés comme intrants pour le classifieur neuronal artificiel le Perceptron Multi-couches pour évaluer sa performance. Les résultats ont montré que la performance du réseau de neurones artificiel est considérablement améliorée lorsque les signaux de vibration débruités sont utilisés en comparaison avec les signaux de vibration brutes. il est constaté que classifieur Perceptron Multi-couches peut être efficacement utilisé pour évaluer la performance de la transformée en ondelettes pour l'analyse des signaux de vibration du palier.

[5] ont proposé une méthode hybride basée sur l'utilisation combinée de la transformée en ondelettes (WT) et les réseaux de neurones artificiels de type de Perceptron multicouches pour la surveillance de la vitesse d'engrenage. L'algorithme proposé permet d'effectuer un diagnostic à un stade précoce de la variation de la raideur d'engrènement quand un endommagement local apparaît, (il est capable de détecter diminution de la rigidité de maillage de 1%). la détection, la localisation et la mise à jour de la vitesse sont prévues et fournies très bientôt et à chaque rotation de l'arbre, donc ce système peut être utilisé comme un outil puissant pour éviter les ruptures catastrophiques des engrenages causées lorsque des points critiques de fonctionnement (vitesse et couple) excitent certains risques potentiels de résonance modifiés par la nouvelle rigidité de maillage.

II. MÉTHODES APPLIQUÉES

A. Transformées en ondelettes

Les transformées en ondelettes sont des fonctions mathématiques qui peuvent être utilisées pour l'analyse des séries temporelles pour mettre en évidence des processus non stationnaires et de localiser des perturbations à l'échelle temporelle et fréquentielle.

Dans le cas du présent travail, l'analyse par ondelettes est utilisé pour décomposer une série de variables observées en diverses composantes pour que ces dernières soient présentées comme les nouvelles entrées du réseau de neurones artificiel.

L'analyse par ondelettes se traduit par des translations et dilatations de la variable étudiée. Le choix de ces translations et dilatations peut se faire de manière continue ou discrète, ce qui correspond à la transformée en ondelettes continue et la transformée en ondelettes discrète.

A.1. Transformées en ondelettes continues (CWT : Continuous Wavelet Transform)

La transformée en ondelettes continue est définie comme suit:

$$\text{CWT}_x^\psi(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \cdot \psi^* \left(\frac{t-\tau}{s} \right) dt \quad (1)$$

Où :

$x(t)$ est le signal à analyser.

τ est le coefficient de translation. Il s'agit d'un nombre réel.

s est le coefficient d'échelle, également appelé facteur de dilatation de ψ . Il s'agit d'un nombre réel qui est l'inverse de la fréquence ($s > 0$).

$\psi(t)$ est l'ondelette mère.

ψ^* est le conjugué de ψ .

Les $\text{CWT}_x^\psi(\tau, s)$ sont les coefficients d'ondelettes.

A.2. Transformée en ondelettes discrète (DWT : Discrete Wavelet Transform)

La transformation en ondelettes discrètes (DWT) est souvent utilisée, en raison de sa simplicité et de réduction du temps de calcul. Cette transformée est faite par discrétisation de la transformée en ondelette en ne prenant simplement que des valeurs discrètes de s et de τ . La transformée en ondelettes discrète sera donc définie comme suit :

$$\begin{aligned} \text{DWT}_x^\psi(j, k) &= \frac{1}{\sqrt{s_0^j}} \int_{-\infty}^{+\infty} x(t) \cdot \psi \left(\frac{t - k \cdot \tau_0 \cdot s_0^j}{s_0^j} \right) dt \\ &= \frac{1}{\sqrt{s_0^j}} \int_{-\infty}^{+\infty} x(t) \cdot \psi(s_0^{-j} t - k \tau_0) dt \quad (2) \end{aligned}$$

Avec $s_0 > 1$ et $\tau_0 > 0$ fixés et $j, k \in \mathbb{Z}$.

Le résultat de cette discrétisation correspond à une série de coefficients d'ondelettes, il s'agit de la décomposition en séries d'ondelettes.

En pratique, on utilise souvent les paramètres $s_0 = 2$ et $\tau_0 = 1$

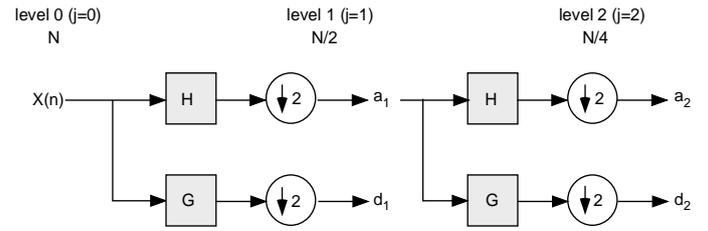
On parle alors de transformée en ondelettes dyadique.

Pour reconstruire la série originale on utilise la transformée en ondelettes discrètes inverse.

En 1989, [6] a proposé un algorithme rapide pour calculer les coefficients d'ondelettes qui repose sur une analyse multi-résolution qui conçoit la transformée en ondelettes discrètes comme une séquence d'application de filtres. En effet, chaque signal est constitué de composantes basses fréquences : appelées approximations et de composantes hautes fréquences : appelées détails.

Selon Mallat, nous pouvons séparer les détails et les approximations en faisant appel à une paire de filtre H et G qui sont un filtre passe bas et un filtre passe haut complémentaires. Le filtre passe bas est une fonction d'échelle alors que le filtre passe haut est une fonction d'ondelette. Ainsi l'analyse multi-résolution permet une décomposition multi-échelle du signal de départ en séparant à chaque niveau de résolution les basses fréquences (approximation) et les hautes fréquences (détails) du signal (Fig.1).

Fig. 1. Décomposition en DWT sur deux niveaux



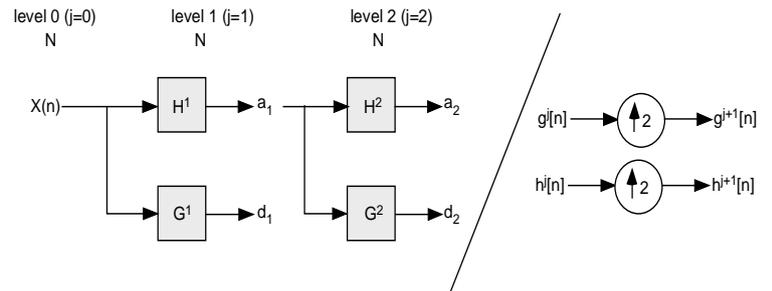
A.3. Transformée en ondelettes stationnaire (SWT : Stationary Wavelet Transform)

A chaque étape de la transformée en ondelette discrète (DWT), le nombre de coefficients à l'échelle j est décimé en moitié à l'échelle $j + 1$, en raison de sous-échantillonnage. Cependant la décimation à l'effet indésirable que nous ne pouvons pas relier l'information à un point de temps donné aux différentes échelles d'une manière simple. Pour surmonter ces problèmes liés à l'utilisation de la transformée en ondelette discrète (DWT), on a utilisé un algorithme redondant pour décomposer le signal, connu sous le nom de l'algorithme de trous ou l'algorithme de Shensa [8] et qui correspond au calcul de la transformée en ondelettes stationnaire (SWT).

La SWT est similaire à la transformée en ondelettes discrète DWT, sauf que le signal n'est pas décimé et à chaque itération différents filtres passe bas et passe haut sont utilisés.

La Fig. 2 illustre le principe de cette décomposition.

Fig. 2. Décomposition en SWT sur deux niveaux (à droite) et les filtres du SWT (à gauche)



Pour un signal $X(n)$ de longueur N qui doit être divisible par avec J un nombre entier qui représente le nombre de décomposition, les coefficients d'approximations et de détails de la SWT pour chaque échelle j sont donnés par :

$$a_{j+1} = \sum_k h_{j+1}(n-k) a_j(k) \quad (3)$$

$$d_{j+1} = \sum_k g_{j+1}(n-k) a_j(k) \quad (4)$$

Où j représente le niveau de décomposition de SWT, k le nombre de coefficient d'ondelette mère et n le numéro d'échantillon. h_j et g_j sont les filtres passe-bas et passe-haut au

niveau j qui sont obtenues par opération de sur échantillonnage. En effet les filtres, à chaque niveau de décomposition sont sur-échantillonnés par l'insertion de zéros entre chaque coefficient de filtre. Ainsi la transformation SWT génère, à chaque niveau, des coefficients d'approximations et de détails qui auront le même nombre d'échantillons que le signal d'entrée original.

Ce processus se répète d'une façon itérative jusqu'à obtenir une représentation multi-échelle du signal original. Par conséquent un signal $X(n)$ décomposé par SWT peut être représenté comme suit :

$$X(n) = a_j(n) + \sum_{j=1}^j d_j(n) \quad (5)$$

Où $a_j(n)$ représente l'approximation du signal d'origine à la j ème niveau de décomposition, tandis que d_1, \dots, d_j représentent les détails de $X(n)$.

La SWT est donc entièrement défini par le choix d'une paire de filtres (c'est-à-h et g) et le nombre de décomposition du signal.

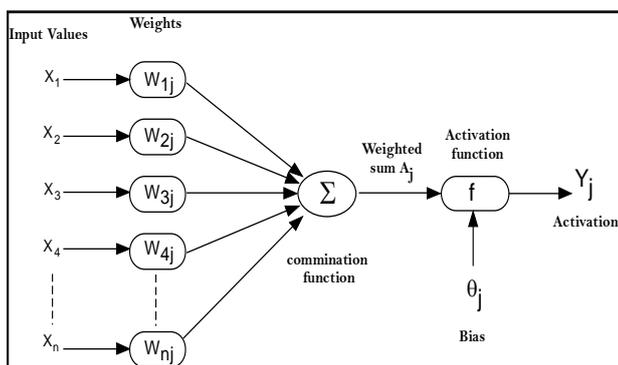
B. Réseaux de neurones artificiels (RNA) : Perceptron Multi-couches (PMC)

B.1. Définition

Un réseau de neurones artificiel est un outil de modélisation mathématique dont l'inspiration originale était le fonctionnement des réseaux de neurones biologique. L'avantage des réseaux de neurones artificiels est leur capacité d'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[7]. Le type Perceptron Multi-Couche (PMC) est le réseau de neurones le plus simples et le plus couramment utilisés.

La structure d'un réseau de neurones artificiel formel et représentée dans la Fig.3

Fig. 3. Structure d'un neurone artificiel



Le calcul des sorties des neurones de la couche cachée et de la couche de sortie s'effectuent en de la manière suivante :

- Définition d'une fonction de combinaison qui réalise la somme pondérée A_j des entrées du neurone. La somme d'activation pondérée est égale à :

$$A_j = \theta_j + \sum_{i=1}^n W_{ij} X_i \quad (6)$$

Où θ_j est le biais de neurone j , W_{ij} est le poids synaptique et X_i est la valeur d'entrée relative à la variable i .

- Calcul de la sortie du neurone j selon la formule ci-après :

$$Y_j = f(A_j) = f(\theta_j + \sum_{i=1}^n W_{ij} X_i) \quad (7)$$

Avec f (fonction d'activation ou de transfert) est une fonction qui anime le neurone en déterminant son activation ; Il existe plusieurs fonctions d'activation (tangente hyperbolique, gaussienne, sigmoïde, ...), mais la plus utilisée est la fonction sigmoïde. Elle s'écrit sous la forme suivante :

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (8)$$

La meilleure architecture du modèle PMC et sa mise en place revient à choisir les fonctions de transfert, à déterminer les entrées pertinentes, le nombre de neurones de la couche cachée, choisir l'algorithme d'apprentissage puis optimiser et tester le réseau.

B.2. Evaluation des performances

Cette étape consiste à évaluer les modèles formés par comparaison de la différence entre les valeurs estimées et les valeurs réelles. Le résultat de l'évaluation est exprimé par deux manières : par des indicateurs statistiques et par l'examen des graphes. Les indicateurs ayant été pris dans cette étude sont : le coefficient NSE (Nash-Sutcliffe efficiency), Le coefficient de détermination (R^2), La moyenne des erreurs quadratiques (MSE), qui sont définis comme suit :

- le coefficient NSE (Nash-Sutcliffe efficiency) :

$$NSE = 1 - \frac{\sum_{i=1}^{i=N} (Y_i^{obs} - Y_i^{sim})^2}{\sum_{i=1}^{i=N} (Y_i^{obs} - Y^{mean\ obs})^2} \quad (9)$$

- le coefficient de détermination R^2 :

$$R^2 = \frac{Cov^2(Y^{sim}, Y^{obs})}{V(Y^{sim}) * V(Y^{obs})} \quad (10)$$

- La moyenne des erreurs quadratiques (MSE) :

$$MSE = \frac{\sum_{i=1}^{i=N} (Y_i^{obs} - Y_i^{sim})^2}{N} \quad (11)$$

Y^{obs} et Y^{sim} sont les valeurs du vecteur cible et vecteur prédiction de neurone de sortie du réseau, $Y^{mean\ obs}$ est la valeur moyenne du vecteur cible et N est le nombre d'échantillons test.

La meilleure prédiction est quand R^2 d'une part et MSE d'autre part tendent vers 1 et 0 respectivement. Le coefficient NSE (Nash-Sutcliffe efficiency) est une statistique normalisée qui détermine l'importance relative de la variance résiduelle par rapport à la variance de données mesurées.

Le coefficient NSE (Nash-Sutcliffe efficiency) varie de $-\infty$ à 1 et se traduit comme suit :

- ✓ $NSE = 1$, correspond à une parfaite modélisation des données observées.
- ✓ $NSE = 0$, indique que les prédictions du modèle sont aussi précises que la moyenne des données observées,
- ✓ $-\infty < NSE < 0$, indique que la moyenne observée est meilleur prédicateur que le modèle.

III. 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. (Fig.4).

Fig.4. Installation de distillation continue



A. 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 volatilisée 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 $0,08m^2$, est placé en tête de colonne pour condenser complètement les vapeurs.

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.

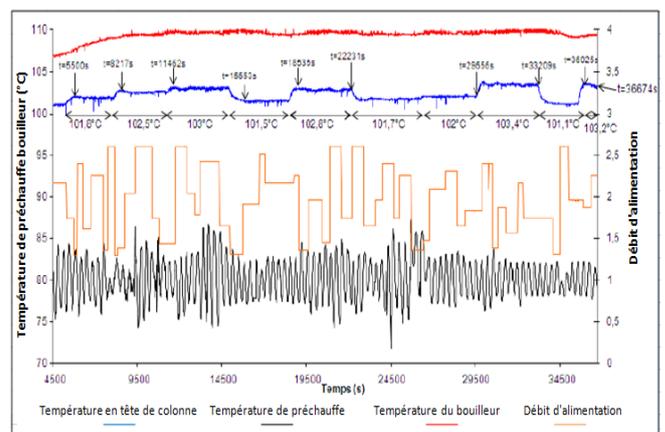
Le garnissage de la colonne de distillation continue favorise le transfert de la matière entre la phase vapeur et la phase liquide. Le type de garnissage choisi pour assurer ce rôle est MULTIKNIT inox 316 L, en plus, pour se rapprocher aux conditions adiabatiques, un calorifuge constitué de laine de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

B. Détermination du mode normal de l'installation de distillation continue

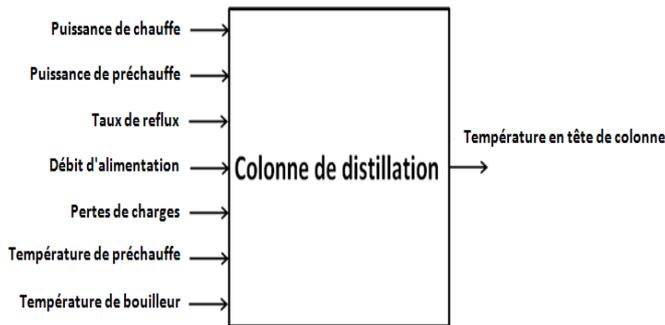
Pour déterminer l'intervalle de travail, nous avons défini l'objectif d'obtenir un mélange riche en méthylcyclohexane, pour cela, et à partir du diagramme isobare liquide vapeur du mélange toluène/méthylcyclohexane, nous avons déterminé une plage de température $[101,1^{\circ}C ; 103,4^{\circ}C]$ équivalente 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 (Fig.5). La définition de cette plage de température découle du fait que la purification de ce mélange binaire en industrie s'effectue dans cette gamme.

Fig.5. Comportement normal de la colonne de distillation continue



Les données pertinentes qui représentent les entrées du système et qui assurent une température constante à la sortie sont schématisées dans la Fig.6.

Fig.6. Comportement normal de la colonne de distillation continue



IV. CONCEPTION DU SYSTÈME HYBRIDE SWT-RNA-PMC

Les modèles hybrides couplant les ondelettes aux réseaux de neurones artificiels sont des modèles qui utilisent, comme entrées, les composants des sous-séries (détails et approximations) qui sont dérivés de l'utilisation de la transformée en ondelette discrète sur les données originales des séries temporelles.

A. Collecte de données

La température en tête de colonne du distillat (T_d) 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).

B. Décomposition en ondelettes stationnaires

Nous avons choisi l'ondelette Haar comme ondelette mère et un nombre de décomposition égale à 2 pour représenter nos signaux dans le domaine temps échelle. Le choix du nombre de décomposition égale à 2 découle de l'application d'une méthode couramment utilisée [9], [10] et [11] suivant la formule ci-après :

$$L = \text{int}[\log(N)] \quad (12)$$

Où L est le niveau de décomposition et N est la longueur du signal.

Dans notre cas, nous avons 960 échantillons, ce qui produit un niveau de décompositions égale à 2 car $[L = \text{int}[\log(960)] = 2]$.

Le choix de l'ondelette Haar pour mettre en œuvre la transformée en ondelettes stationnaire (SWT) est justifié par le fait que les coefficients d'ondelettes de Haar sont calculés uniquement à partir de données obtenues précédemment dans le temps.

L'ondelette de Haar est définie par une paire de filtres passe-bas et haut donné par :

$$h = \left[\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right] \quad (13)$$

$$g = \left[-\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right] \quad (14)$$

Le tableau 1 montre les coefficients de l'ondelette mère de Haar utilisés par la SWT pour deux niveaux de décomposition:

TABLEAU 1. COEFFICIENTS DE L'ONDELETTE DE HAAR UTILISÉS PAR LA SWT

	Niveau 1 (j=1)	Niveau 2 (j=2)
Filtre passe haut, G^j	$g^1[0] = -0.7071067812$ $g^1[1] = 0.7071067812$	$g^2[0] = -0.7071067812$ $g^2[1] = 0$ $g^2[2] = 0.7071067812$ $g^2[3] = 0$
Filtre passe bas, H^j	$h^1[0] = 0.7071067812$ $h^1[1] = 0.7071067812$	$h^2[0] = 0.7071067812$ $h^2[1] = 0$ $h^2[2] = 0.7071067812$ $h^2[3] = 0$

Nous avons passé par deux étapes principales :

- 1- Décomposition du signal en coefficients de détails et d'approximation,
- 2- Utilisation des données décomposées comme nouvelles entrées du système étudié.

V. RÉSULTATS ET DISCUSSION

Pour choisir le meilleur modèle, nous avons testé les trois configurations possibles, voir tableau 2).

TABLEAU 2. RÉCAPITULATIF DES MODÈLES TESTÉS

	Entrées = Variables non décomposées (base de données initiale)	Entrées décomposées par SWT = (Approximations Niveau 2, Détails Niveau 1 et 2)	Entrées décomposées = Approximations Niveau 2 seules
Meilleure architecture proposée	[7-8-1]	[14-3-1]	[7-17-1]
Coefficient de détermination R^2	0,603	0,786	0,860
Coefficient NSE	0,584	0,784	0,853
Erreur Moyenne Quadratique (MSE)	0,025	0,0004	0,009

Nous remarquons que le modèle qui tient compte des approximations seules, donne de bons résultats par rapport aux autres modèles et cela concernant les critères de performance à savoir $R^2 = 0.86$, $NSE = 0.853$ et $MSE = 0.009$.

L'algorithme de Levenberg Marquardt a été utilisé pour déterminer les poids et les biais du réseau neuronal PMC.

Pour choisir la meilleure architecture du modèle, trois tests d'évaluation des performances ont été établis, le coefficient de détermination R^2 , le coefficient d'efficacité NSE et l'erreur quadratique moyenne (MSE) (Fig.7, Fig.8 et Fig.9).

Fig.7. Coefficient de détermination R^2

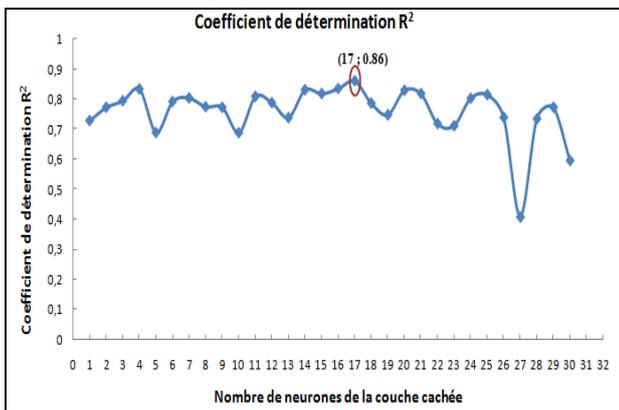


Fig.8. Coefficient d'efficacité NSE

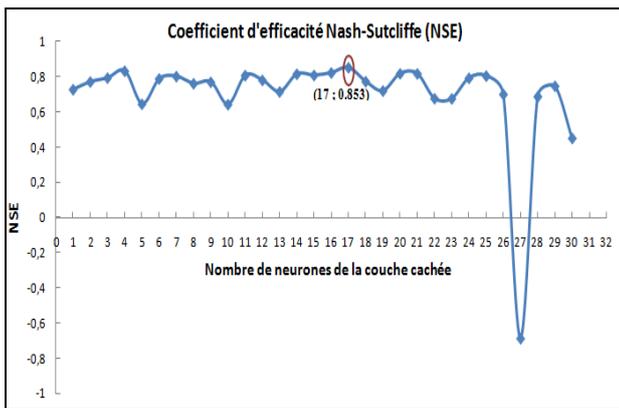
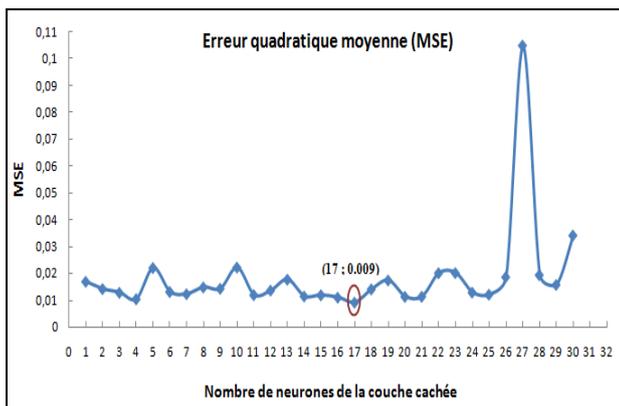


Fig.9. Erreur quadratique moyenne MSE

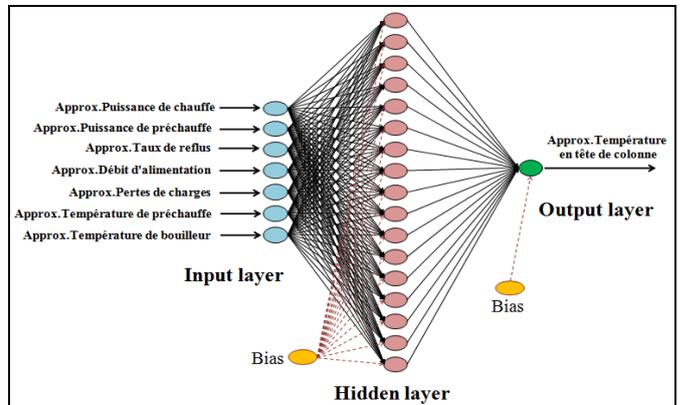


On remarque d'après les figures (Fig.7, Fig.8 et Fig.9) que la meilleure architecture du réseau est [7-17-1].

Apprentissage et validation

Le réseau de neurones artificiels "Perceptron Multi-couches" se compose d'une couche d'entrées de 7 neurones, d'une couche cachée contenant 17 neurones et d'une couche de sortie contenant un seul neurone. (Fig.10).

Fig.10. Architecture neuronale [7-17-1]

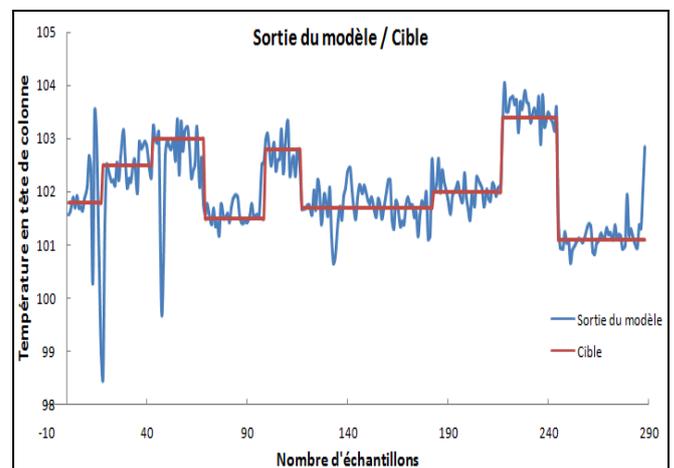


La base d'apprentissage du réseau de est composée de 672 échantillons, i.e. 70% de la base de données totale et les poids et les biais sont ajustés par l'algorithme de Levenberg Marquardt.

Une fois l'architecture, les poids et les biais du réseau de neurones sont fixés, il faut savoir si ce modèle neuronal est susceptible d'être généralisé.

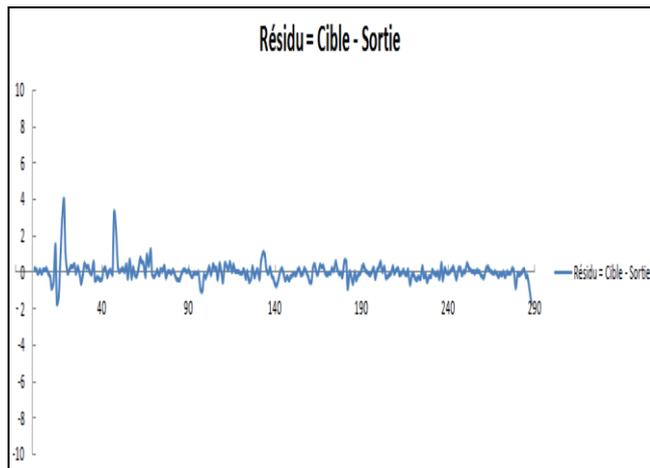
La validation de l'architecture neuronale [7-17-1] consiste donc à juger sa capacité de prédiction de la température en tête de colonne en utilisant les poids et les biais calculés durant l'apprentissage, pour les appliquer à une autre base de données tests composés de 288 échantillons c'est-à-dire 30% de la totalité des données. (Fig.11).

Fig.11. Résultats de la prédiction de la température dans la tête de la colonne SWT-RNA-PMC [7-17-1]



La moyenne des valeurs absolues des résidus (Résidu = Target – Output) est de l'ordre de 0,017. (Fig.12)

Fig.12. Graphe des résidus



VI. CONCLUSION

Dans cette étude, L'apprentissage du modèle neuronal PMC développé a été effectué en prenant comme entrées du système les approximations seules obtenues en décomposant chaque variable d'entrée à l'aide de la transformée en ondelettes stationnaire.

En ce qui concerne les poids et les biais du réseau neuronal, ils sont obtenus à l'aide de l'algorithme de Levenberg Marquardt. 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 SWT-ANN-MLP [7-17-1] qui a permis d'obtenir un coefficient de détermination R^2 de **0.86**, un coefficient d'efficacité NSE de **0.853** et une erreur quadratique moyenne MSE de **0.009**, ce qui représente le meilleur résultat en comparaison avec les deux autres modèles testés qui sont respectivement le premier modèle des entrées non décomposées avec un R^2 de l'ordre de 0.603 et NSE de 0.584 et le deuxième modèle des entrées décomposées en approximations et détails qui a donné un R^2 de 0.786 et NSE de 0.784.

En plus, cette méthode hybride de modélisation basée sur la décomposition en ondelettes stationnaire et les réseaux de neurones artificiels de type Perceptron multi-couches a montré

sa robustesse par rapport à d'autres méthodes de modélisation appliquées sur la même installation industrielle à savoir l'utilisation des réseaux de neurones artificiels à fonction de base radiale (RBF) et les réseaux de neurones artificiels de type Perceptron Multi-couches.

References

- [1] R. Cheng, Y. Ping "A novel approach to fuzzy wavelet neural network modeling and optimization" International Journal of Electrical Power and Energy Systems, Vol. 64, pp. 671-678, 2015.
- [2] B. Boudad, H. Sahbi, I. Manssouri, T. Manssouri "Contribution to the prediction of drought in the basin of Inaouène using RNA coupled to the Stationary Wavelet Decomposition" International Journal of Engineering Technology and Computer Research (IJETCR), Vol. 2, issue 6, pp. 58-70, 2014.
- [3] B. Boudebbouz, I. MANSSOURI, A. MOUCHTACHI, B. El Kihel "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), Vol.3, issue 6, pp. 2829-2835, 2014.
- [4] H.S. Kumar, P. P. Srinivasa, N.S. Sriram, S. Vijay "ANN based evaluation of performance of wavelet transform for condition monitoring of rolling element bearing" Procedia Engineering Journal, Vol. 64, pp. 805-814, 2013.
- [5] J. Sanz, R. Perera, C. Huerta "Gear dynamics monitoring using Discrete Wavelet Transform and Multi Layer Perception Neural Networks" Applied Soft Computing, Vol. 12, pp. 2867-2878, 2012.
- [6] S.G. Mallat "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation" IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, No. 7, pp. 674-693, 1989.
- [7] J. Adamowski, K. Sun "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, pp. 85-91, 2010.
- [8] M.J. Shensa "The Discrete Wavelet Transform: Wedding the A Trous and Mallat Algorithms" IEEE Transaction on Signal Processing, Vol. 40, No 10, (1992).
- [9] Nourani, Vahid, Alami, T. Mohammad, Aminfar, H. Mohammad "A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation" Engineering Applications of Artificial Intelligence, Vo. 22, No 3, pp. 466-472, 2009.
- [10] N. Mohammad, S.N. Amir "A combined Wavelet- Artificial Neural Network model and its application to the prediction of groundwater level fluctuations" Geopersia Journal, Vol. 2, No 2, pp. 77-91, 2012.
- [11] W. Wang, J. Ding "Wavelet network model and its application to the prediction of hydrology" International Journal of Nature and Science, Vol. 1, No 1, 2003.