REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISRTE DE L'ANSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE

SCIENTISIQUE

UNIVERSITE YAHIA FARES DE MEDEA



Faculté de **T**echnologie

Mémoire de fin d'étude de Master

Filière: Génie des procédés.

Spécialité: Génie Chimique.

Utilisation d'une méthode d'intelligence artificielle pour la modélisation d'un procédé de traitement des eaux

Présenté par:

SAÏFOUR Khadidja

FEDDAK Ferial

Proposé et Dirigé par:

Dr. SEDIRI Meriem (Promotrice)

Dr. IBRIR Abdellah (Co-promoteur)

Promotion 2022

الحمد لله الذي بنعمته
تتم الصالحات،
وبفضله تتنزل
الخيرات والبركات
وبتوفيقه تتحقق
المقاصد والغايات

Remerciements

En premier lieu, Nous remercions ALLAH le Tout Puissant de nous avoir donné la volonté, la force, la patience et le courage pour réaliser ce travail.

Nous tenons à adresser nos plus sincères remerciements à notre Directeur de mémoire :Dr. Sediri Meriem et à notre Co- Directeur : Dr. Ibrir Abdellah pour le temps précieux qu'ils ont consacré ainsi que pour leurs suggestions, tant sur le plan scientifique que moral.

Nos plus vifs remerciements s'adressent ainsi aux : nos chers parents pour le suivi quotidien des activités de recherche, nos enseignants : Dr Cherif Si-moussa, Pr. Maamar Laidi pour leurs soutiens moraux.

Nous tenons également à présenter notre profonde gratitude aux membres de juré, Dr : KERMET SAID Hadjira et Dr : FERGANI Zineb d'avoir accepté de juger ce modeste travail.

Merci à tous, ceux qui nous ont aidés de près ou de loin durant nos années de recherche et d'études.

Nous ne pouvons conclure sans un mot de remerciement à tous nos enseignants et collègues.

Dédicace

Avec l'aide de dieu, j'ai pu réaliser ce travail que je tiens à dédicacer.

Á mes parents qui m'ont apporté leur appui durant toutes ces années d'études, pour leurs sacrifices consentis ainsi que pour la confiance dont ils m'ont gratifiée.

Á mon frère et ma belle sœur pour leurs encouragements.

Á ma sœur, son mari et sa petite famille pour leur soutien.

Á toute ma famille d'avoir été très patiente envers moi durant ces moments stressants.

Á toutes mes amies pour leur solidarité inconditionnelle.

Á mon binôme ainsi que sa famille.

Á mes camarades de la promotion 2022.

Saifour Khadidja

Dédicace

Je dédie ce modeste travail de Master

A ma très chère maman ***Samia MAKHLOUFI***

Je tu dois ce que je suis aujourd'hui grâce à ton amour, à ton patience, à ton innombrables sacrifices et pour tout l'enseignement que ton m'avez transmis.

Que ce modeste travail, soit pour vous une petit compensation et reconnaissance envers ce que vous avez faite d'incroyable pour moi.

A mes chers grands-parents, ***Houssine, Rekia***

A ma chère sœur ***Khalida*** *ainsi sa petite famille*

A mes chers oncles, ***Abderrahmane*** *et* ***Mohamed***

A mes chers tantes, ***Mounira, Dalila, Hayet***

A mes chers cousins, ***Fares, Wail***

A toute la famille ***MAKHLOUFI, BENALLEL***

Un spécial dédicace à A mon fiancé ***Djamel*** *et sa famille*

A toute mes collègues de la promotion 2022

A tous qui ont contribué dans ma formation depuis mon enfance.

Tous qui connaissent ***Ferial*** *de près ou de loin.*

A mon binôme ***KHADIDJA*** *et à toute sa famille «* ***SAIFOUR*** *»*

Ferial Feddak

استخدام طريقة ذكاء اصطناعي لنمذجة عملية معالجة المياه

الملخص

الهدف من هذا العمل هو نمذجة ظاهرة الامتزاز المكون من عنصرين. تجمع هذه الدراسة بين نموذجين رياضيين، أولهما هو إنشاء نموذج عصبي والثاني يعتمد على المنطق الضبابي (ANFIS)، القادرين على التنبؤ بالكميات الممتصة لمزيج ثلاثي (أزرق قاعدي41 ، أحمر قاعدي18 ، أحمر قاعدي 46) بواسطة مادة الامتصاص (هيدروكسيد النيكل β -ni $(OH)_2$). تعتمد هذه النمذجة على تطوير برنامج MATLAB®. أظهرت النتائج أن الشبكة العصبية الاصطناعية المحسنة (RNAO) لها بنية (6-11-4-1): {6 خلايا عصبية في شبكة الدخول؛ 11 خلية عصبية في الشبكة المخفية الأولى؛ 4 خلايا عصبية في الشبكة المخفية الثانية و خلية عصبية واحدة في شبكة الخروج}. يستنسخ ANFIS (نظام الاستدلال العصبي الغامض التكيفي) بأمانة البيانات التجريبية المأخوذة من الأدبيات مقارنة بنموذج RNAO بدقة جيدة جدًا: جذر متوسط الخطأ التربيعي (MSE) = 0.3627 ومعامل التحديد R^2 = 0.996. تؤكد هذه النتائج متانة نموذج المنطق الضبابي الراسخ.

الكلمات المفتاحية: الأصباغ، الامتزاز ، النمذجة ، الشبكة العصبية الإصطناعية ، نظام الإستدلال الضبابي العصبي التكيفي .

Utilisation d'une méthode d'intelligence artificielle pour la modélisation d'un procédé de traitement des eaux

Résumé

L'objectif de ce travail est de modéliser le phénomène de l'adsorption bi-composant. Cette étude regroupe deux modèles mathématiques dont le première est d'établir un modèle neuronale et le deuxième basé sur la logique floue (ANFIS), capables de prédire les quantités adsorbées pour un mélange ternaire (Basic Blue 41, Basic Red 18, Basic Red 46) sur l'adsorbant (l'hydroxyde de nickel β-ni$(OH)_2$). Cette modélisation s'articule sur l'élaboration d'un programme MATLAB®. Les résultats montrent que le réseau de neurones artificielle optimisé (RNAO) a une architecture de (6-11-4-1) : {6 neurones dans la couche d'entrée ; 11 neurones dans la première couche cachée ; 4 neurones dans la deuxième couche cachée et 1 seul neurone dans la couche de sortie}. L'ANFIS (Système d'inférence neuro floue adaptative) reproduit fidèlement les données expérimentales tirées de la littérature par rapport au modèle de RNAO avec une très bonne précision : une erreur quadratique moyenne (RMSE) = 0.3627 et un coefficient détermination R^2 = 0.9964. Ces résultats confirment la robustesse du modèle de la logique floue établi.

Mots clés : Colorants, Adsorption, Modélisation, RNA, ANFIS.

Use of an artificial intelligence method for modeling a water treatment process

Abstract

The objective of this work is to model the phenomenon of two-component adsorption. This study brings together two mathematical models, the first of which is to establish a neuronal model and the second based on fuzzy logic (ANFIS), capable of predicting the quantities adsorbed for a ternary mixture (Basic Blue 41, Basic Red 18, Basic Red 46) on the adsorbent (nickel hydroxide β-ni(OH)2). This modeling is based on the development of a MATLAB® program. The results show that the optimized artificial neural network (RNAO) has an architecture of (6-11-4-1): {6 neurons in the input layer; 11 neurons in the first hidden layer; 4 neurons in the second hidden layer and 1 single neuron at the output layer}. The ANFIS (Adaptive Fuzzy Neuro Inference System) faithfully reproduces the experimental data taken from the literature compared to the RNAO model with very good precision: a root mean square error (MSE) = 0.3627 and a determination coefficient R^2 = 0.9964. These results confirm the robustness of the established fuzzy logic model.

Keywords: Dyes, Adsorption, Modeling, RNA, ANFIS.

Table des matières

Table des matières ……....I

Abréviations VI

Liste des tableaux.....VII

Liste des figures.....VIII

Introduction général.....1

CHAPITRE I : GENERALITES SUR L'ADSORPTION

I.1.Introduction……..3

I.2.Définition……..3

I.3.Types d'adsorption……3

I.3.1. (Physisorption) Adsorption physique……4

I.3.2 . (Chimisorption) Adsorption chimique…….....4

I.4.Mécanismes d'adsorption……..5

I.5.Facteurs influençant sur le phénomène d'adsorption……6

I.5.1.La surface spécifique…….....6

I.5.2.pH……...6

I.5.3.La nature d'adsorbat……...6

I.5.4. La porosité…….....6

I.5.5.La température……...6

I.5.6.La concentration du polluant…….....6

I.5.7.La vitesse d'agitation…….....6

I.5.8. Le rapport solide-liquide……...7

I.6.Les différents types d'adsorbants……..7

I.6.1.Les charbons actifs…….....7

I.6.2.Les zéolithes…….....7

I.6.3.Les gels de silice……..7

I.6.4.Les alumines activées……...7

I.6.5.Les argiles activées……...8

I.7. Isotherme d'adsorption……...8

I.7.1.Classification des isothermes d'adsorption…….....8

I.7.2. Différents modèles d'isothermes……..10

I.7.2.1. Isotherme de Langmuir……..10

I.7.2.2.Isotherme de Freundlich…….....11

I.7.2.3. Isotherme de Temkin…….....11

I.7.2.4. Isothermes de Dubinin-Radushkevish…….....12

I.7.2.5. Isotherme de Halsey……..12

I.7.2.6. Isotherme d'adsorption de Harkins-Jura……....13

I.8.La cinétique d'adsorption……13

I.9. Modèles de la cinétique de l'adsorption……..13

I.9.1. Modèle de la cinétique du pseudo premier ordre (modèle Lagergren)……13

I.9.2. Modèle de la cinétique du pseudo second ordre……..13

I.9.3. Modèles de la diffusion intra particule……14

I.10.Conclusion……15

CHAPITRE II :GENERALITES SUR LES METHODES D`INTELLIGENCE ARTIFICIELLES

II.1 Introduction……...16

II.2.Les réseaux de neurones artificiels……16

II.2.1. Historique sur les réseaux de neurones……..16

II.2.2.Définition……...17

II.2.3. Modèle « boîte noire »……..18

II.2.4.Principe du neurone artificiel……....19

II.2.5.Neurones biologiques et artificiels…….20

II.2.6. Architecture des réseaux de neurone……22

II.2.6.1.Réseaux non bouclés……...23

II.2.6.2.Réseaux bouclés……..23

II.2.7.Connexion entre les neurones……24

II.2.8. Réseau de neurones artificiel de perceptron multicouches (type feedfoward)24

II.2.9. Fonctions d'activations……26

II.2.10. Choix de la structure du réseau……..26

II.2.11. Apprentissage des réseaux de neurones…….27

II.3. ANFIS……29

II.3.1. Introduction…….29

II.3.2. Définition…….29

II.3.3. Avantages et inconvénients de la logique floue et des RNA……..29

II.3.4. Les différentes combinaisons neuro-floues……..30

II.3.4.1 . Réseau flou neuronal……30

II.3.4.2. Modèles neuro-flous coopératifs ……..30

II.3.4.3. Modèles neuro-flous hybrides…….....30

II.3.5. Optimisation d'un Système d'Inférence Floue.….....30

II.3.6. Description des réseaux Neuro-Flou utilisés ANFIS (Adaptative neuro-fuzzy inference systems)……..31

II.4. Conclusion……..34

CHAPITRE III :MATERIELS ET METHODES

III.1. Introduction……..35

III.2. Revue critique sur l'utilisation des RNA et ANFIS pour la modélisation de l'adsorption multi-composante……..35

III.3. Base de données …….....39

III.3.1. Choix des paramètres d'entrées et de sorties.…… ……...39

III.3.2. Préparation de la base de données ……..……..40

III.3.3. Etude statistique des paramètres influençant de l'adsorption et le taux des concentration des colorant……...40

III.3.4. Normalisation des données ……..……...43

III.3.5. Dé-normalisation des données ……..……43

III.4.Développement de réseau de neurone artificielle…….…….....43

III.4.1. Choix des paramètres de RNA ……...43

III.5. Modélisation de l'adsorption des colorants par l'ANFIS.……..……46

III.5.1. La méthodologie de modélisation par l'ANFIS ……46

CHAPITRE IV : RÉSULTATS EXPÉRIMENTAUX

IV.1. Introduction ……47

IV.2. Résultats et discussion par RNA……..47

IV.2.1. Concept du réseau de neurones de type feedforward……47

IV.2.2. Nombre de neurones et de couches cachées……..48

IV.2.3. Concept du réseau de neurone optimal de type feedforward (MLP)……49

IV.2.4. Interprétation des résultats RNA……50

IV.3. Résultats et discussion par l'ANFIS…….53

IV.3.1. Interprétation des résultats ANFIS…….53

IV.4. Comparaison entre le RNA et ANFIS……...56

IV.5. Interface graphique……56

IV.5. Conclusion…….57

Conclusion générale……..58

Références bibliographique……59

Annexes……..65

LISTE DES ABREVIATIONS

LISTE DES ABREVIATIONS

ANN : Réseau de Neurone Artificiel (Artificial Neural Network).

Ea : Energie d'activation (J).

ERA : Erreur relative absolue.

FFNN : Réseau de Neurone de Rétro-Propagation (Feed Forward Neural Network).

Logsig : Logarithmique sigmoïde.

MAE : mean absolue erreur (erreur absolue moyenne).

MAPE : mean absolue pourcentage erreur (l'erreur de pourcentage absolue moyenne).

MLP-ANN : Perceptron Multicouches –Réseau de Neurone Artificiel (Multi-Layer Perceptron - Artificiel Neural Network).

MSE : Erreur Quadratique Moyenne.

NRMSE: Normalised root mean square error (Racine Carrée de l'Erreur Quadratique Moyenne normalisée).

R : Coefficients de corrélations.

$\mathbf{R^2}$: Coefficients de détermination.

RMSE : Root mean square error (Racine Carrée de l'Erreur Quadratique Moyenne).

RNA : Réseau de Neurone Artificiel.

SEA : Somme des Erreurs Absolues.

Tansig : Tangent Sigmoïde.

LISTE DES TABLEAUX

Chapitre I

Tableau I.1 : Différences entre adsorption chimique et adsorption physique…….4

Chapitre II

Tableau II.3.1. Comparaison entre la logique floue et les RNA……...30

Chapitre III

Tableau III.1. Répartition de la base de données d'entrés……..…40
Tableau III.2. Répartition de la base de données de sortie……40
Tableau III.3 : Description statistique de l'ensemble des données……41
Tableau III.4 : Structure du RNA optimisé pour l'adsorption bi-composante……..44

Chapitre IV

Tableau IV.1 : Résultats des paramètres statistiques du modèle RNAO développé dans ce travail. ……..53
Tableau IV.2. Paramètres statistiques du modèle ANFIS développé dans ce travail…….....55
Tableau IV.3. Comparaison entre le RNA et ANFIS……...56

LISTE DES FIGURES

Chapitre I

Figure I.1 : Représentation du Phénomène d'adsorption…….3

Figure I.2: Domaines d'existence d'un soluté lors de l'adsorption sur un matériau microporeux……5

Figure I.3 : Classes des isothermes d'après Gilles et Coll……9

Chapitre II

Figure II.1. Diagramme schématique d'une modèle neuronale « boîte noire »…….....19

Figure II.2.Neurone artificiel……....20

Figure II.3.Représentation d'un neurone biologique par Nicolas Rougier…….....21

Figure II.4.Réseau de neurone artificiel……22

Figure II.5.Mise en correspondance neurone biologique/ neurone artificiel……...22

Figure II.6.Réseau non bouclé…….…….23

Figure II.7.Réseau bouclé…….24

Figure.II.8. Le neurone amont, j le neurone aval et W_{ij} le poids de la connexion…….24

Figure II.9.Topologie d'un réseau de neurone de type feedfoward……..…25

FigureII.10.Erreur moyenne sur la base d'apprentissage en fonction du nombre d'itérations.28

Figure II.11 : Architecture d'ANFIS…….32

Chapitre III

Figure III.1 : Analyse de corrélation des données d'entrée pour les modèles prédictifs…..…..42

Figure III.2 : Organigramme de la méthodologie de calcul du RNA……45

Figure III.3 : Architecture du modèle ANFIS…….……..46

Chapitre IV

Figure IV.1 : Réseau de neurones artificiels de type feedforward……..…….49

Figure IV.2 : la différence en termes d'erreur pour les nombres de neurones dans chaque couche cachée……....50
Figure IV.3 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour les phases d'apprentissage, test et validation (Globale)……..51
Figure IV.4 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase d'apprentissage……..51
Figure IV.5 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase de test……..52
Figure IV.6 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase de validation……52
Figure IV.7 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour les phases d'apprentissage, et test (Globale)……...……54
Figure IV.8 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour la phase d'apprentissage……..54
Figure IV.9 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour la phase de test…….…….55
Figure IV.10. Interface graphique du modèle ANFIS …….56

INTRODUCTION GÉNÉRALE

Introduction Générale

Au cours de ces dernières années et dans différents domaines, le monde a connu un développement très important grâce à l'apport de la science et de la technologie. Malheureusement, cet essor n'a pas apporté que les avantages mais aussi des inconvénients. En effet, parmi les problèmes les plus aigus, il y'a la contamination des ressources hydrauliques. Au contact avec les activités humaines des pays modernes, l'eau se charge d'acides, de lessives, de graisses, de détergents et d'infinités composants étrangers à la nature.

Pour résoudre ce phénomène de pollution, plusieurs techniques de séparation in situ ou ex situ ont été étudiées. La plus utilisée est celle de l'adsorption.

L'adsorption est employée ainsi pour indiquer un certain nombre de processus de traitement indépendants (adsorption physique et chimique). Les avantages principaux de l'adsorption sont : la rapidité de la réaction, la sélectivité, la réversibilité).

L'adsorption séquentielle en mode statique des systèmes adsorbant(s)/ adsorbat(s) est très complexe et a engendré un grand intérêt dans de nombreux secteurs industriels. Le processus séquentiel à une particularité : les espèces chimiques s'adsorbent en même temps avec un degré de compétition différent, dépendant de plusieurs paramètres thermo physicochimiques et morphologiques. Il est à l'origine d'une multitude d'applications particulièrement dans le domaine agro-alimentaire, pharmaceutique ou encore dans celui de la chimie et la pétrochimique.

Dans le domaine industriel, connaître le comportement du système adsorbant(s)/ adsorbat(s) ainsi que l'interférence des phénomènes thermo-physicochimiques et morphologiques qui le contrôlent ou encore la prédiction des cinétiques de sorption est fondamentale pour le processus industriel [1].

Pour d'écrire la capacité de délimitation d'un biosorbant et pour obtenir des courbes de percées décrivant le comportement du processus de l'adsorption, deux approches peuvent être utilisées : La première consiste à établir un modèle qui peut décrire le processus et la deuxième approche consiste à réaliser une expérience directe et exploiter les résultats expérimentaux afin d'établir les relations entre les paramètres d'entrés et de sorties.

Cependant l'approche expérimentale est souvent délicate, couteuse, prend beaucoup de temps [2]. Ce qui a poussé les chercheurs à établir la modélisation en développant des modèles qui décrivent de manière adéquate le comportement des processus.

La modélisation de l'adsorption utilisant les approches d'intelligences artificielles comme les réseaux de neurones artificiels (RNA) et les systèmes à interférence neuro-floue adaptatifs (ANFIS) pour la prédiction de l'objectif désirée qui est très appliquée au cours de ces dernières années à cause de leur parallélisme élevé, robustesse et leur capacité de traiter les relations complexes entre les paramètres d'entrés sur la sortie [3].

Le manuscrit comporte quatre chapitres principaux :

-Le premier chapitre : comprend des notions de bases sur le phénomène d'adsorption statique.

-Le deuxième chapitre : nous s'intéresse sur les notions de bases pour l'apprentissage des méthodes d'intelligences artificielles.

-Le troisième chapitre : est consacré à présenté le matériel et les méthodes utilisées pour développer les modèles d'intelligences artificiels.

-Le quatrième chapitre : s'intéresse à présenter les différents résultats obtenus avec leurs interprétations.

On termine notre travail avec une conclusion et des perspectives qui peuvent être envisagées dans le futur.

CHAPITRE I :

GENERALITES SUR L'ADSORPTION

I.1.Introduction :

Parmis les différent procédés de traitement utilisés dans la dépollution et la purification **,** celui de l'adsorption compte parmis les moyens les plus utilisés dans les industrie pétrolières **,** pétrochimiques et chimiques [4] **.** C'est une tèchnique fiable pour l'enlèvement des substanes toxiques [5**,**3] **.** En raison de sa facilité d'emploi **,** son efficacité et son faible coût **,** cette techniques est très utilisée pour la séparation et la purification des gaz et des liquides dans différents domaines [3,6].

I.2.Définition :

L'adsorption est un phénomène physico-chimique par lequel des atomes ou des molécules de gaz ou de liquide se fixent sur une surface solide selon divers processus plus ou moins intenses tels que les interactions de Van Der Waals ou les interactions dipolaires**.** La substance qui se fixe est appelée **«** adsorbat **»,** et le solide qui est le siège de l'adsorption est nommé **«** adsorbant **»** [7]. Le phénomène inverse par lequel les molécules se détachent s'appelle **«** la désorption **»** [8].

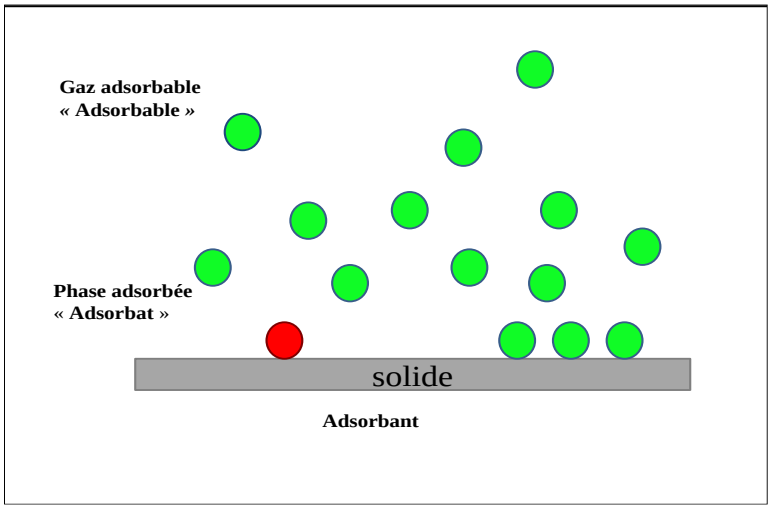


Figure I.1 : Représentation du Phénomène d'adsorption.

I.3.Types d'adsorption :

Les interactions entre l'adsorbat et l'adsorbant [9] c'est-à-dire La fixation d'un élément dissous dans l'eau sur la surface d'une particule solide [8,10]**.** Permettent de définir deux types d'adsorption, à savoir, l'adsorption physique (physisorption) et l'adsorption chimique (chimisorption) qui se distinguent par la chaleur d'adsorption, la vitesse, la réversibilité et la spécificité du processus [11 ,12].

I.3.1. (Physisorption) Adsorption physique :

C'est une adsorption de type physique [13], elle est dû à des forces d'interaction physique entre les atomes constituant la couche superficielle du solide et les molécules de la phase gazeuse ou liquide se trouvant au contact du solide**.** Ces forces d'interaction font intervenir des forces de Van Der Waals ainsi que des liaisons hydrogènes**.** Elles existent quelle que soit la nature du solide et des molécules d'adsorbat**.** Il existe également des forces électrostatiques (coulombiennes) si le solide ou le gaz sont polaires par nature**.** Dans ce type d'adsorption les énergies mises en jeu sont faibles et inférieures à 20 kcal/mol [14]

I.3.2 . (Chimisorption) Adsorption chimique :

Provient d'une réaction chimique en libérant une énergie d'interaction comprise entre 40 et 400 KJ/Mol avec formation de liaisons chimiques entre les molécules d'adsorbat et la surface d'adsorbant. Des modifications peuvent être effectuées dans les structures des molécules [15,16].

Tableau I.1. Différences entre adsorption chimique et adsorption physique.

	Adsorption chimique	**Adsorption physique**
Nature des Interactions	Liaisons fortes (grande affinité adsorbant / adsorbât)	Liaisons faibles (forces de Van der waals)
Quantité adsorbée	Déterminée par le nombre de sites de la surface (monocouche au maximum)	Possibilité de superposition de plusieurs couches d'atomes adsorbés
Caractère de la surface	Hétérogène : les sites ne sont pas équivalents de point de vu énergétique	Plus au moins homogène
Caractéristique du phénomène	Spécifique	Non Spécifique
Chaleur d'adsorption	Ne dépasse pas 50kj / mol	De 100 à1000kj / mol
Vitesse d'adsorption	Parfois lente à cause de la grande barrière d'énergie d'activation	Rapide sauf s'il y'a diffusion dans des micropores
Réversibilité du phénomène	Limitée	Très marquée

Mobilité des espèces adsorbées	Limitée	Très grande
Influence de l'élévation de la température	Faible et parfois favorable suite à l'activation de la surface	Diminue avec l'augmentation de la température

I.4.Mécanismes d'adsorption :

Il existe de nombreux mécanismes d'adsorption d'un soluté sur la surface d'un solide. Parmi ces mécanismes, on peut citer [17] :

- ✓ L'adsorption par échange d'ions.
- ✓ L'adsorption par polarisation des ponts d'hydrogènes.
- ✓ L'adsorption mettant en jeu l'attraction électrostatique.
- ✓ L'adsorption mettant en jeu une paire d'électrons.

L'adsorption se déroule principalement en quatre étapes :

1. Diffusion de l'adsorbât de la phase liquide externe vers la phase localisée au voisinage de la surface de l'adsorbant.

2. migration extragranulaire de la matière (transport du soluté à travers le film liquide vers la surface des grains).

3. Transfert intragranulaire de la matière (transfert de la matière dans la structure poreuse de la surface extérieure des graines vers les sites actifs).

4. Réaction d'adsorption au contact des sites actifs, une fois adsorbée, la molécule est considérée fixée.

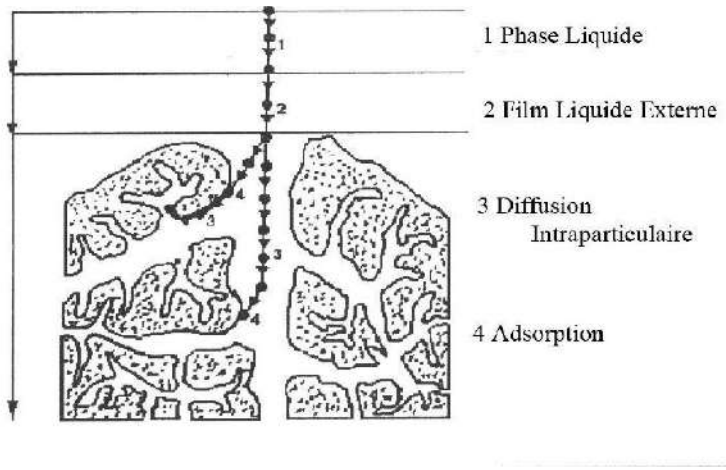


Figure I.2 : Domaines d'existence d'un soluté lors de l'adsorption sur un matériau microporeux.

I.5.Facteurs influençant le phénomène d'adsorption :

Les différents paramètres qui influent sur l'équilibre d'adsorption sont :

I.5.1.La surface spécifique :

La surface spécifique est présentée comme étant sa surface par unité de masse exprimée en (m^2/g). Pour arriver à un effet d'adsorption important, il est indispensable que la surface de l'adsorption soit la plus grand possible [18]. On peut augmenter la surface totale par broyage de la masse solide ; ce qui multiplie encore sa porosité totale [19].

I.5.2.PH :

La charge superficielle de l'adsorbant ainsi que la structure de l'adsorbat peuvent être conditionnées par le PH [20]. Dans la plupart des cas, les meilleurs résultats sont acquis aux pH les plus faibles. Cette propriété s'applique particulièrement à l'adsorption de substances acides [21].

I.5.3.La nature d'adsorbat :

Lorsque la solubilité est élevée cela veut dire qu'il y a une forte liaison entre le soluté et le solvant [22]. « Moins une substance est soluble, mieux elle est adsorbée » [23].Donc, pour qu'une molécule soit adsorbée, il faut d'abord rompre le lien avec le solvant [24].

I.5.4. La porosité :

La porosité c'est le rapport du volume des pores au volume totale, tout en prennent en considération la forme des pores et leur connexion entre eux [25].

I.5.5.La température :

L'adsorption est un phénomène endothermique ou exothermique suivant le matériau adsorbant et la nature de molécules adsorbées [26].

- ✓ L'adsorption physique est exothermique ; de ce fait le taux d'adsorption est meilleur à basse température.
- ✓ Lorsque la chimisorption est endothermique, une température élevée est favorable pour le déroulement du processus [27; 28].

I.5.6.La concentration du polluant :

La concentration du polluant en solutions influe de façon directe sur l'adsorption. L'augmentation de cet dernier diminue la capacité d'adsorption dans les en tenant compte les autres conditions opératoires constantes [29].

I.5.7.La vitesse d'agitation :

La quantité adsorbée dépend de type d'agitateur utilisé et de l'intensité de l'agitation [30]. Lorsque l'intensité de l'agitation augmente, la vitesse d'adsorption croît.

I.5.8. Le rapport solide-liquide :

La vitesse d'adsorption à un rapport étroit avec la masse du solide puisque cette vitesse d'adsorption est proportionnelle à la masse du solide [31].

I.6.Les différents types d'adsorbants :

Les adsorbants les plus abondants industriellement sont : les charbons actifs**,** les zéolithes, les gels de silice, les alumines et les argiles activées [32].

I.6.1.Les charbons actifs :

Les charbons actifs sont des matériaux constitués principalement de matière carbonée [3]. Ils sont préparés par pyrolyse d'une matière contenant du carbone, pour aboutir un charbon de bois qui est ensuite oxydé par la vapeur d'eau afin de d'obtenir une structure microporeuse. On trouve plusieurs qualités de charbons actifs, suivant le précurseur et les conditions de traitement. Il existe aussi des charbons actifs dits « chimique », parce qu'ils sont activés à chaud en présence d'agents chimiques déshydratants, comme l'acide phosphorique ou le chlorure de Zinc, ce sont des adsorbants hydrophobes.

Les charbons actifs sont les adsorbants les plus répandus parce que leur porosité est importante, leur coût est moindre et leur domaine d'application est vaste [33].

I.6.2.Les zéolithes :

Les zéolithes sont des adsorbants qui appartiennent à la famille des alumino-silicates cristallises microporeux de formule générale (AlO2M, nSiO2), où M représente le plus souvent un métal alcalin ou alcalino-terreux [34]. Il existe deux types de zéolithes : les zéolithes naturelles et les zéolithes synthétiques [3].

I.6.3.Les gels de silice :

Les gels de silice sont préparés à partir de $Si(OH)_4$ en phase aqueuse, obtenu par acidification d'un silicate de sodium, ou bien à partir d'un sol de silice [35]. Les groupements Si- OH conduisent à des liaisons hydrogène [36].

Le gel de silice sous forme des grains est poreux et la taille des grains liée fortement à la méthode de préparation utilisée. Il existe deux types de gels de silice : les microporeux qui sont très hydrophiles, et les macroporeux, qui différent entre eux par leur taille des pores.

I.6.4.Les alumines activées :

Les alumines activées sont obtenues par thermolyse flash du tri hydroxyde d'aluminium $Al(OH)_3$ qui conduit à un produit de composition approximative Al_2O_3, 0.5 H_2O [35]. Elles possèdent une structure poreuse résultant du départ de molécules d'eau. La surface des pores est entourée par des groupements Al-OH, dont l'adsorption est achevée par les liaisons Hydrogènes [3].

I.6.5.Les argiles activées :

Ayant une structure cristalline différente, Les argiles activées sont des alumino-silicates de formule toutefois proche des zéolithes. Ce sont des produits naturels utilisés surtout pour le séchage.

I.7. Isothermes d'adsorption :

Une isotherme d'adsorption est la courbe reliant l'activité de l'adsorbat contenu dans une atmosphère donnée et connue à la quantité d'adsorbat adsorbée sur un solide en équilibre avec cette atmosphère.

Un grand nombre de modèles d'isothermes d'adsorption a été développé par différents chercheurs et les isothermes ont été classées suivant leur forme par Brunauer, Emmett et Teller en 1938 (d'ou le nom de classification BET). La plupart de ces isothermes ont d'abord été proposées en phase gaz, puis adaptées aux phénomènes en phase liquide, parmi les quelles l'isotherme de Freundlich et l'isotherme de Langmuir [37].

I.7.1.Classification des isothermes d'adsorption :

D'après Gilles et Coll, les isothermes d'adsorption sont classé ont quatre principales classe à solubilité limitée [38].

Cette classification tient compte entre autre d'un certain nombre d'hypothèses [37] :

- Le solvant s'adsorbe sur les mêmes sites que le soluté. Ceci implique l'existence d'une compétition d'adsorption entre le solvant et le soluté.
- Le nombre de sites susceptibles d'accueillir les molécules de soluté à la surface du solide diminue quand la quantité adsorbée augmente.
-L'orientation des molécules à la surface. On peut citer le cas où les molécules sont adsorbées verticalement ou horizontalement sur la surface.
- Enfin, les interactions attractives ou répulsives entre les molécules adsorbées se manifestent d'une façon notable dans le phénomène d'adsorption.

Les isothermes sont présentées sur la figure :

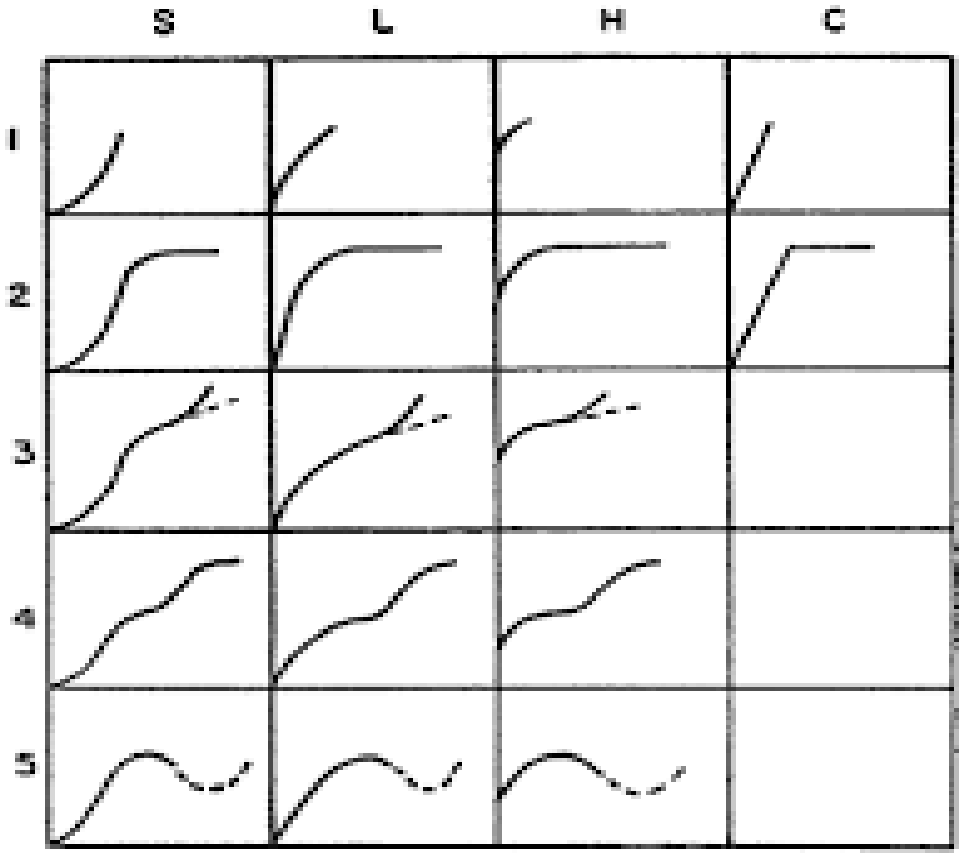


Figure I.3: Classes des isothermes d'après Gilles et Coll.

S : Sigmoïde ; L : Langmuir ; H : Haute affinité ; C : partition Constante

Classe L :

À faible concentration en solution, les isothermes de classe L présentent, une concavité tournée vers le bas qui traduit une diminution des sites libres au fur et à mesure de la progression de l'adsorption. Ce phénomène se produit lorsque les forces d'attraction entre les molécules adsorbées sont faibles.

Classe S :

Les isothermes de cette classe présentent, à faible concentration, une concavité tournée vers le haut. Les molécules adsorbées favorisent l'adsorption ultérieure d'autres molécules (Adsorption coopérative). Ceci est dû aux molécules qui s'attirent par des forces de Van Der Waals, et se regroupent en îlots dans lesquels elles se tassent les unes contres les autres.

Classe H :

La partie initiale de l'isotherme est presque verticale, la quantité adsorbée apparaît importante à concentration quasiment nulle du soluté dans la solution. Ce phénomène se produit lorsque les interactions entre les molécules adsorbées et la surface du solide sont très fortes.

L'isotherme de classe H est aussi observée lors de l'adsorption de micelles ou de polymères formées à partir des molécules de soluté.

Classe C :

Les isothermes de cette classe se caractérisent par une partition constante entre la solution et le substrat jusqu'à un palier. La linéarité montre que le nombre de sites libres reste constant au cours de l'adsorption. Ceci signifie que les sites sont créés au cours de l'adsorption. Ce qui implique que les isothermes de cette classe sont obtenues quand les molécules de soluté sont capables de modifier la texture du substrat en ouvrant des pores qui n'avaient pas été ouverts préalablement par le solvant.

I.7.2. Différents modèles d'isothermes :

De multiples lois ont été proposées pour l'étude de l'adsorption. Ces lois expriment la relation entre la quantité adsorbée et la concentration en soluté dans un solvant à une certaine température. Parmi ces lois les plus utilisée, on peut rappeler :

I.7.2.1. Isotherme de Langmuir :

Etant le plus utilisé, le modèle de Langmuir repose sur les hypothèses suivant [39] :

-La surface est énergétiquement homogène.

-Une seule entité est adsorbée par site.

-L'activité à un site donné n'affecte pas l'activité des sites adjacents.

-Les molécules adsorbées ne réagissent pas entre elles.

-L'adsorption se fait en une seule couche complètement saturée et l'adsorbant présent une capacité d'adsorption limitée (q_m).

L'isotherme de Langmuir est décrite par la relation suivante :

$$q_e = \frac{q_m\, C_e\, K_L}{1+C_e K_L} \qquad \text{(I.1)}$$

- ✓ q_m: Capacité maximale d'adsorption (mg/g).
- ✓ K_L: constante d'équilibre de Langmuir (l/mg) [40,41].

Des développements de l'équation (I.1) conduisent à des formes linéaires de l'isotherme de Langmuir dont deux sont couramment utilisées [42,43] :

$$\text{Langmuir I: } \frac{1}{q_e} = \frac{1}{q_m\, C_e\, K_L} + \frac{1}{q_m} \qquad \text{(I.2)}$$

$$\text{Langmuir II : } \frac{C_e}{q_m} = \frac{1}{q_m\, K_L} + \frac{1}{q_m} \qquad \text{(I.3)}$$

Ce modèle est caractérisé par un paramètre d'équilibre R_L:

$$R_L = \frac{1}{1+C_0\,K_L} \quad \text{(I.4)}$$

- ✓ R_L = 0 : adsorption irréversible;
- ✓ 0 <R_L< 1 : adsorption thermodynamiquement favorable;
- ✓ R_L = 1 : adsorption linéaire (du type C);
- ✓ R_L > 1 : adsorption thermodynamiquement défavorable [44,45].

I.7.2.2.Isotherme de Freundlich :

L'isotherme de Freundlich admet la coexistence de sites d'énergies différentes, il admet également l'interaction entre les particules adsorbées et ne prévoit pas de limites supérieures à l'adsorption. Ce modèle qui à été proposé en 1926 est l'indicatif d'une surface hétérogène. Il repose sur l'équation empirique suivant :

$$q_e = K_F . C_e^n \quad \text{(I.5)}$$

- ✓ K_F: constante de Freundlich, relative à la capacité d'adsorption.
- ✓ n : constante de Freundlich, relative à l'intensité de l'adsorption. [46,47]

La forme exploitée la plus courante est le tracé en échelle logarithmique des variations de q_e en fonction de Ce :

$$\log q_e = \log K_F + n \log C_e \quad \text{(I.6)}$$

Une autre exploitation possible des résultats par l'isotherme de Freundlich consiste à tracer en échelle logarithmique les variations du coefficient de distribution K_d en fonction de q_e :

$$\log K_d = \left(\frac{1}{n}\right) \log K_F + \left(\frac{n-1}{n}\right) (\log q_e) \quad \text{(I.7)}$$

Il est généralement admis que :

- ✓ n < 1 : adsorption thermodynamiquement favorable :
- ✓ < n < 0.5 : bonne adsorption.
- ✓ 0.5 < n < 1 : adsorption modérée.
- ✓ n = 1 : adsorption linéaire (du type C).
- ✓ n > 1 : adsorption faible [44,48].

I.7.2.3. Isotherme de Temkin :

Le modèle proposé par Temkin suppose que l'abaissement de la chaleur d'adsorption avec l'augmentation du taux de recouvrement n'est pas logarithmique comme dans le cas des systèmes conduisant à l'équation de Freundlich, mais linéaire notamment à moyen et faible taux de recouvrement ; Cette linéarité peut être due a :

- La répulsion entre espèces adsorbées sur la surface uniforme

-L'hétérogénéité de la surface

L'isotherme de Temkin est représentée par l'équation suivante :

$$\theta = \frac{q_e}{q_m} = \frac{RT}{\Delta Q} \cdot \ln K_0 \; C_0 \qquad (I.8)$$

Avec :

- ✓ θ: Taux de recouvrement de la surface de l'adsorbant.
- ✓ C_e: Concentration à l'équilibre, exprimé en (mg/l).
- ✓ q_e : Quantité du produit adsorbé par unité de masse d'adsorbant exprimé en (mg/g).
- ✓ q_m: Capacité maximale théorique exprimée en (mg/g).
- ✓ K_0: Constante d'équilibre.

La linéarisation de l'équation de Temkin conduit a :

$$q_e = [q_m(\frac{RT}{\Delta\theta})].\ln Ce + [q_m(\frac{RT}{\Delta Q})] \ln K_0 \qquad (I.9)$$

En traçant q_e= (lnCe), on obtient une droite dont la pente et l'ordonné à l'origine permettent de déterminer La chaleur d'adsorption ΔQ et la constante d'équilibre K_o [49].

I.7.2.4. Isothermes de Dubinin-Radushkevish :

L'isotherme de Dubinin-Radushkevish suppose une surface hétérogène. Elle est exprimé par l'équation suivant [50] :

$$q_e = q_m \, e^{-K.\varepsilon^2} \qquad (I.10)$$

Avec :

- ✓ ε : Le potentiel de Polanyi ε = (R.T).ln (1 + 1/Ce).
- ✓ q_e: La quantité d'ions métallique adsorbés par poids spécifique (mg/g).
- ✓ q_m : La capacité d'adsorption (mg/g).
- ✓ C_e : La concentration en équilibre des ions métalliques en solution (mg/l).
- ✓ K : Une constante liée à l'énergie d'adsorption (mol2 /KJ2).
- ✓ R : La constante universelle des gaz parfaits (KJ/K.mol).
- ✓ T : Température (K).

L'isotherme de D–R peut être exprimée par sa forme linéaire comme suit :

$$\text{Log } (q_e) = \log (q_m). -K'. \varepsilon^2 \qquad (I.11)$$

I.7.2.5. Isotherme de Halsey :

L'isotherme d'adsorption de Halsey peut être donnée par la formule suivante [51] :

$$q_e = \exp\left(\frac{\ln K_H - \ln C_e}{n}\right) \qquad (I.12)$$

Où K_H= est la constante du Halsey, n : exposant ;

L'équation de linéarisation de ce modèle est donnée comme suit :

$$\ln q_e = \frac{1}{n} \ln K - \frac{1}{n} \ln C_e \quad \text{(I.13)}$$

I.7.2.6. Isotherme d'adsorption de Harkins-Jura :

La relation de l'isotherme d'adsorption du Harkin-Jura est exprimée comme suivant [52] :

$$q_e = \left(\frac{A}{B+\log C_e}\right)^{\frac{1}{2}} \quad \text{(I.14)}$$

Où A et B représentent les paramètres d'isotherme.

La linéarisation de ce modèle est donnée par la relation suivante **:**

$$\frac{1}{q_e^2} = \frac{B}{A} - \frac{1}{A} \log C_e \quad \text{(I.15)}$$

I.8.La cinétique d'adsorption :

La cinétique d'adsorption contrôlée par la diffusion des molécules, le phénomène d'adsorption atteint son équilibre assez rapidement (quelques secondes à quelques minutes) ; néanmoins, il faut se prolonger sur des temps très longs pour les adsorbants microporeux en en raison du ralentissement de la diffusion des molécules dans ces structures de dimensions voisines du diamètre des molécules du fluide [53].

I.9. Modèles de la cinétique de l'adsorption :

I.9.1. Modèle de pseudo premier ordre (modèle Lagergren) :

Dans ce modèle de pseudo premier ordre (modèle Lagergren), Il a été supposé que dans ce modèle la vitesse de sorption à un instant t est proportionnelle à la différence entre la quantité adsorbée à l'équilibre q_e et la quantité q_t adsorbée à cet instant et que l'adsorption est réversible [54].

La constante de vitesse d'adsorption du premier ordre est déduite à partir du modèle établi par Lagergren[55]. La loi de vitesse s'écrit comme suit :

$$\frac{dq}{dt} = K_1(q_e - q_t) \quad \text{(I.16)}$$

- ✓ K_1 : La constante de vitesse pour une cinétique du pseudo premier ordre (1/min).
- ✓ q_t : La capacité d'adsorption à l'instant t (mg/g).
- ✓ q_e : La capacité d'adsorption à l'équilibre (mg/g).

La constante de vitesse d'adsorption (K_1) est donnée après intégration par l'équation suivante:

$$\log\ (q_e - q) = \log(q_e) - \frac{K_1}{2.303} \cdot t \quad \text{(I.17)}$$

I.9.2. Modèle de pseudo second ordre :

L'équation du pseudo second ordre est souvent utilisée avec succès pour décrire la cinétique de la réaction de fixation des polluants sur l'adsorbant .Ce modèle du pseudo second ordre permet de caractériser les cinétiques d'adsorption en prenant en compte à la fois le cas d'une fixation rapide des solutés sur les sites les plus réactifs et celui d'une fixation lente sur les sites d'énergie faible [56].

$$\frac{\mathrm{dq}}{\mathrm{dt}} = K_2\,(q_e - q_t) \qquad \text{(I.18)}$$

L'intégration de la solution (équation17) donne :

$$\frac{1}{q_t} = \frac{1}{K_2\, q_e^2} + \frac{1}{q_e} \cdot t \qquad \text{(I.19)}$$

Avec :

- ✓ K_2: Constante de vitesse d'adsorption pour le pseudo second ordre (g/mol.min).
- ✓ q_e : Quantité d'adsorbat à l'équilibre par gramme d'adsorbant (mg/g).

La quantité d'adsorption à l'équilibre (q_e) et la constante du pseudo second ordre k_2 peuvent être déterminées expérimentalement à partir de la pente et de l'ordonnée à l'origine de t/q_t en fonction de t.

I.9.3. Modèle de la diffusion intra particule :

Généralement, le procédé d'adsorption de soluté pour un mélange solide-liquide est caractérisé soit par un transfert de masse externe (diffusion à la couche limite), ou bien par une diffusion intra-particule ou par les deux.

Le mécanisme d'adsorption chimique implique la réaction entre les groupes fonctionnels de surface des adsorbeurs et les adsorbats [3].

Le modèle de diffusion intra particulaire (transfert de masse interne), permet de constater l'existence de cette diffusion intra particulaire. Il est basé sur une équation donné par Weber et Morris [56].

$$Q_t = K_d \cdot t^{\frac{1}{2}} \qquad \text{(I.20)}$$

- ✓ K_d : La constante de la diffusion intra-particulaire en mg. g^{-1} $temps^{-1/2}$.

Pour déterminer la nature du modèle de la diffusion intra-particule (film ou pore) les cinétiques d'adsorption d'un soluté dans un adsorbant de géométrie sphérique sont racées et modélisées par les expressions des coefficients des pores ou de film données par Crank [57].

Les équations utilisées afin de calculer les coefficients de diffusion intra-particule sont écrites sous la forme suivante :

$$\frac{q_t}{q_e} = 1 - \frac{6}{\pi^2}\, e^{\frac{(-D_P\,.\,\pi^2 \cdot t)}{a^2}} \qquad \text{(I.21)}$$

$$\frac{q_t}{q_e} = 6\text{-}\left(\frac{D_f}{\pi\, a^2}\right)^{\frac{1}{2}} .t^{\frac{1}{2}} \qquad \text{(I.22)}$$

- ✓ D_P : Coefficient de diffusion de pore en $cm^2\ s^{-1}$.
- ✓ D_f: Coefficient de diffusion du film en $cm^2\ s^{-1}$.
- ✓ q_t : quantité du polluant adsorbée à l'instant t en mg. g^{-1}.
- ✓ q_e : quantité du polluant adsorbée à l'équilibre en mg. g^{-1}.
- ✓ a : diamètre de la particule sphérique en cm.

I.10.Conclusion :

Le phénomène d'adsorption présenté est un processus qui a le pouvoir d'être appliqué aux traitements des effluents. C'est surtout la question de l'adsorption statique qui a été soulevée dans ce chapitre. Différentes types et mécanismes d'adsorption ainsi que les facteurs influençant ce processus ont été étudiés. Dans le prochain chapitre on va entamer les méthodes d'intelligences artificielles comme étant des modèles utilisées pour prédire et modéliser plusieurs phénomènes y compris l'adsorption.

CHAPITRE II :

GENERALITES SUR LES METHODES D`INTELLIGENCE ARTIFICIELLES

II.1 Introduction :

Ce chapitre s'articule sur les méthodes d'intelligences artificielles (IA) telle que les réseaux de neurones artificielles (RNA) et les systèmes d'inférence neuro-flou intégratif (ANFIS) comme étant des techniques très appliquées pour prédire le comportement d'un processus donné.

Ces méthodes sont dues aux interactions locales, Elles sont très utilisées car elles avoir deux grandes propriétés : l'apprentissage et la robustesse. Elles sont utilisées avec succès dans plusieurs domaines de reconnaissance, d'exploration et de synthèse telles que les applications biologiques, médicales, industrielles, de génération de contrôle, d'ingénierie logicielle, la prévision météorologique, la conjection du marché, la reconnaissance faciale, le pilotage automatique, la robotique, les domaines environnementaux, finances [58,59,60].
L'élaboration de la modélisation à plusieurs objectifs [61], elle permet de :
- Simuler un processus, soit par la détection d'anomalies de fonctionnement, soit par le diagnostic de pannes.
- Faite une synthèse d'une loi de commande.
- Gagner le temps de calculs et de consommation.

Dans ce présent chapitre on va présenter des notions de base sur ces méthodes d'intelligences artificielles comme des approximateurs universels de fonctions.

II.2.Les réseaux de neurones artificiels :

II.2.1. Historique sur les réseaux de neurones :

Les recherches menées dans le domaine du connexionnisme ont démarré avec la présentation en 1943 par W. MCCulloch et W. Pitts d'un modèle simplifié de neurone biologique communément appelé neurone formel. Ils montrèrent également théoriquement que des réseaux de neurones formels simples peuvent accomplir des fonctions logiques, arithmétiques et symboliques complexes.
En 1949, D. Hebb initie, dans son ouvrage "The Organization of Behavior", la notion d'apprentissage. Deux neurones entrant en activité simultanément vont être associés (c'est-à dire que leurs contacts synaptiques vont être renforcés). On dit de loi de Hebb et d'associationnisme.
En 1969, Les recherches sur les réseaux de neurones ont été pratiquement abandonnées lorsque M. Minsky et S. Papert ont révèle leur livre « Perceptrons » (1969) et démontré les

limites théoriques du perceptron, en particulier, l'impossibilité de traiter les problèmes non linéaires par ce modèle.

En 1982, Hopfield développe un modèle qui utilise des réseaux totalement connectés basés sur la loi de Hebb pour définir les notions d'attracteurs et de mémoire associative.

En 1984 c'est la découverte des cartes de Kohonen avec un algorithme non supervisé basé sur l'auto-organisation et suivi une année plus tard par l'appareil de Boltzman (1985). [62] . L'année 1986 est considérée comme une galet angulaire (Basheer and Hajmeer 2000) dans l'histoire récente des RNA puisque (Rumelhart, Hinton, and Williams 1985) ont redécouvert l'algorithme d'apprentissage par rétro propagation (back propagation) après son évolution initial par Werbos [63] .

II.2.2.Définition :

Il existe plusieurs définitions de réseau de neurone artificiel. Haykin, en 1994 a donné la définition suivant : Un réseau de neurones est un processus partagé de manière massivement parallèle, qui a une propension naturelle à mémoriser des connaissances de façon expérimentale et de les rendre disponibles pour l'utilisation. Il ressemble au cerveau en deux points :

- La connaissance est acquise au travers d'un processus d'apprentissage.
- Les poids des connections entre les neurones sont utilisés pour mémoriser la connaissance [3].

Le nom de cette méthode d'intelligence est inspiré de neurones du cerveau humain. Elles sont mentionnés ainsi les réseaux connexionnistes ou réseaux neuromimétiques [64].

Ces réseaux sont solidement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau [62].

Les neurones artificiels sont souvent appliqués sous forme de réseaux qui diffèrent selon le type de connections entre les neurones, une cinquantaine de types peut être dénombrée. En guise d'exemples nous citons : le perceptron de Rosemblat, les réseaux de Hopfield etc.…..

Ces derniers sont les plus utilisés dans le domaine de la modélisation et de la commande des procédés. Ils sont constitués d'un nombre fini de neurones qui sont agencés sous forme de couches. Les neurones de deux couches adjacentes sont interconnectés par des poids. L'information dans le réseau se propage d'une couche à l'autre, on dit qu'ils sont de type « feedforward ». Nous distinguons trois types de couches :

Couche d'entrée : les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation.

Couches cachées : chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transformation selon sa fonction d'activation qui est en général une fonction sigmoïde. Par la suite, il envoie cette réponse aux neurones de la couche suivante.

Couche de sortie : elle joue aussi le rôle des couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone [65.66].

II.2.3. Modèle « boîte noire » :

Le terme de « boîte noire » s'oppose aux termes de « modèle de connaissance » ou « modèle de comportement interne » qui désignent un modèle mathématique établi à partir d'une analyse physique (ou chimique, physico-chimique, économique, etc.) du processus que l'on étudie. Ce modèle peut contenir un nombre borné de paramètres ajustables, qui possèdent, une signification physique. Nous verrons par la suite que les réseaux de neurones peuvent être utilisés pour l'élaboration de modèle « boîte grise », intermédiaire entre les modèles « boîtes noires » et les modèles de connaissance.

Le modèle « boîte noire » (figure II.10) constitue la forme la plus primitive de modèle mathématique : il est réalisé uniquement à partir de données expérimentales ou d'observations ; il peut avoir une valeur prédictive, dans un certain domaine de validité, mais il n'a aucune valeur explicative. Ainsi, le modèle de l'univers selon Ptolémée était un modèle « boîte noire » : il ne donnait aucune explication de la marche des astres, mais il permettait de la prédire avec toute la précision souhaitable au regard des instruments de mesure disponibles à l'époque.

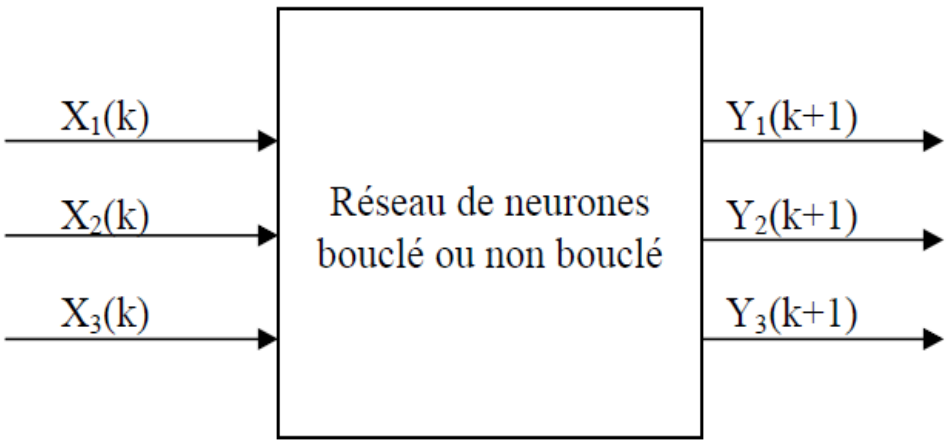


Figure II.1. Diagramme schématique d'un modèle neuronal « boîte noire ».

Entre la boîte noire et le modèle de connaissance se situe le modèle semi-physique, ou modèle « boîte grise » (appelé aussi modèle hybride), qui contient à la fois des équations résultant d'une théorie, et des équations purement empiriques, résultant d'une modélisation de type « boîte noire »[62].

II.2.4.Principe du neurone artificiel :

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont ou des capteurs composant la machine dont il fait partie. A chacune de ses entrées est associé un poids représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour nourrir un nombre variable de neurones en aval. A chaque connexion est associé un poids.

Il est commode de représenter graphiquement un neurone comme indiqué sur la figure II.1. Cette représentation est à l'origine de la première vague d'intérêt pour les neurones formels, dans les années 1940 à 1970 [66].

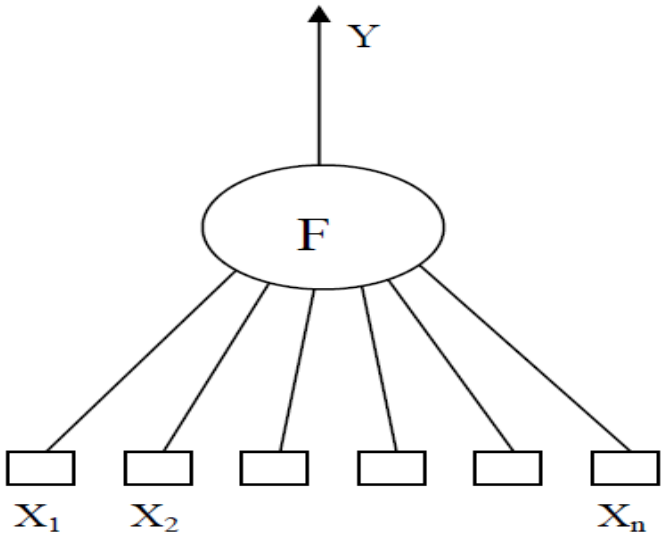


Figure II.2. Neurone artificiel [10].

Le neurone réalise alors trois opérations sur ses entrées :

- Pondération : multiplication de chaque entrée par un paramètre appelé poids de connexion,
- Sommation : une sommation des entrées pondérées est effectuée
- Activation : passage de cette somme dans une fonction, appelée fonction d'activation.

La valeur calculée est la sortie du neurone qui est transmise aux neurones suivants [66].

II.2.5.Neurones biologiques et artificiels :

Dans le cerveau humain l'apprentissage se fait à travers des neurones qui sont connectés par l'axone, les synapses et les dendrites [67].

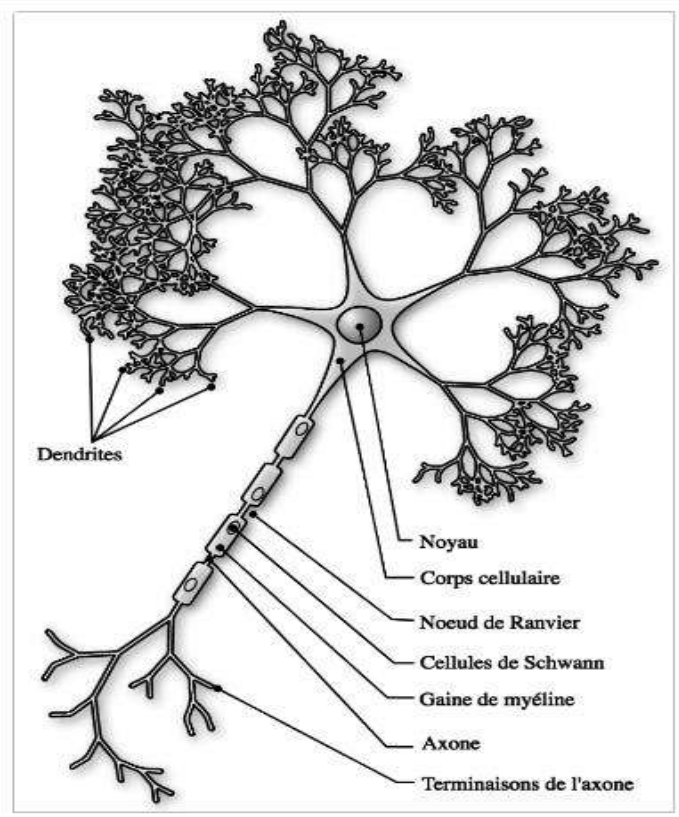


Figure II.3. Représentation d'un neurone biologique par Nicolas Rougier .

Le neurone biologique est composé d'un corps cellulaire (soma) qui contient le noyau de la cellule nerveuse, dans cet endroit que l'influx nerveux prend naissance, il représente l'état d'activité du neurone et il se subdivise pour les dendrites. Les dendrites sont des ramification tubulaires courtes qui forment autour du corps cellulaire une espèce d'arborescence.

La conjonction entre deux neurones est nommé la synapse.

Le réseau de neurone artificiel (Figure II.4) accueilli des entrées qui sont similaires aux impulsions électrochimiques.

Les poids représentent les informations contenues dans le cerveau et données aux entrées de chaque neurone. Le système possède une caractérisation de tolérance aux fautes due au grande nombre de neurones.

La sortie obtenue à partie du calcul de la sommation des entrées est pondérée par des coefficients. Le calcule est fait utilisant une fonction non linéaire qui est généralement une fonction sigmoïde. [62,68].

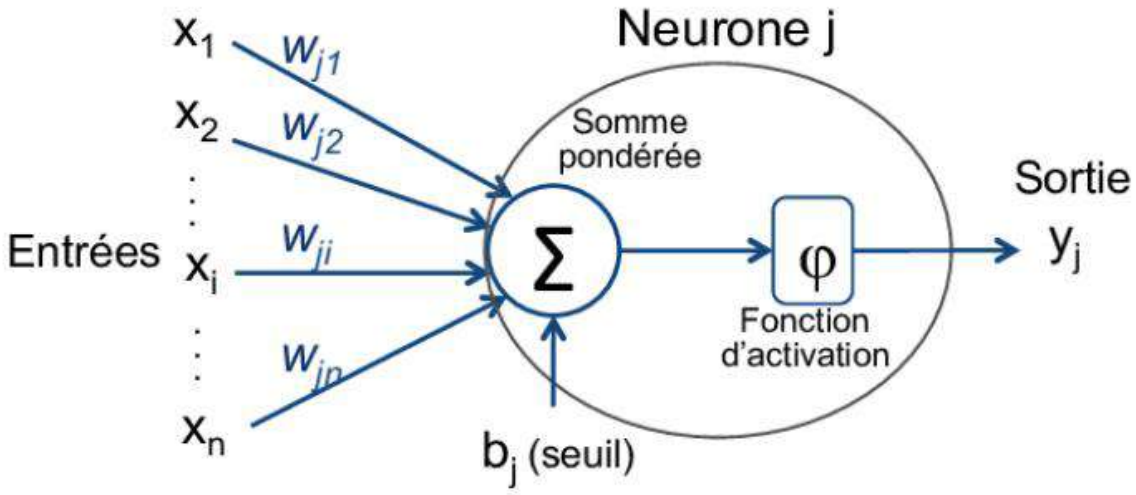


Figure II.4.Réseau de neurone artificiel .

La comparaison entre le neurone artificiel et le neurone biologique et montré sur la figure(II.5). Chaque élément de neurone artificiel a son inspiration dans le neurone biologique.

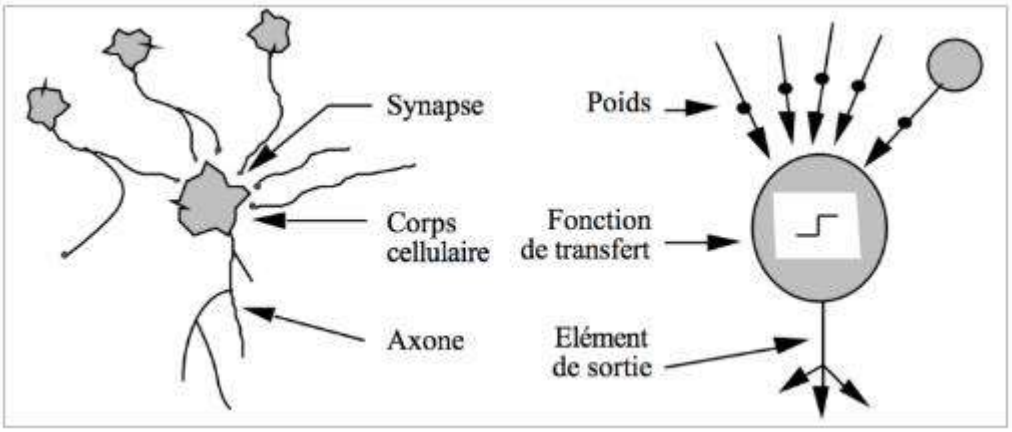


Figure II.5. Mise en correspondance neurone biologique/ neurone artificiel [69].

II.2.6. Architecture des réseaux de neurone :

On distingue deux structures de réseau, en fonction du graphe de leurs connexions, c'est-à-dire du graphe dont les noeuds sont les neurones et les arêtes les «connexions» entre ceux-ci :

- Les réseaux de neurones statiques (ou acycliques, ou non bouclés).
- Les réseaux de neurones dynamiques (ou récurrents, ou bouclés) [62].

II.2.6.1.Réseaux non bouclés :

Ce sont des réseaux unidirectionnels sont retour en arrière (feedfoward). Le signal de sortie est directement obtenu après l'application du signal d'entrée . C'est tous les neurones ne sont pas des organes de sortie, on parle de neurones cachés ,(figure II.6) (POGGIO ,1990) [69] .

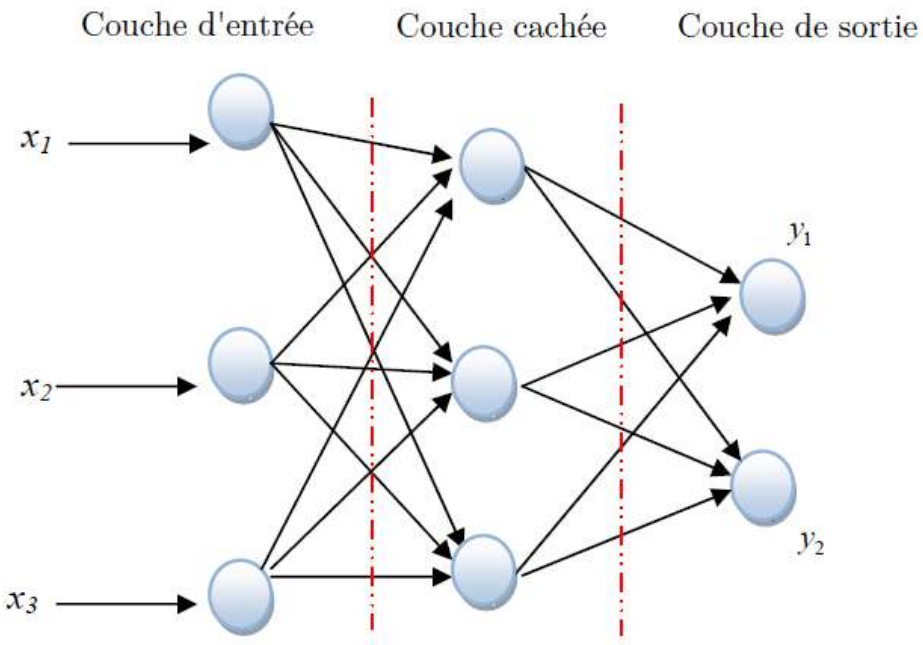


Figure II.6.Réseau non bouclé [69].

II.2.6.2.Réseaux bouclés :

Il s'agit de réseaux de neurones avec retour en arrière (feedback network ou récurrent network) (POGGIO ,1990),(Figure II.7).[69].

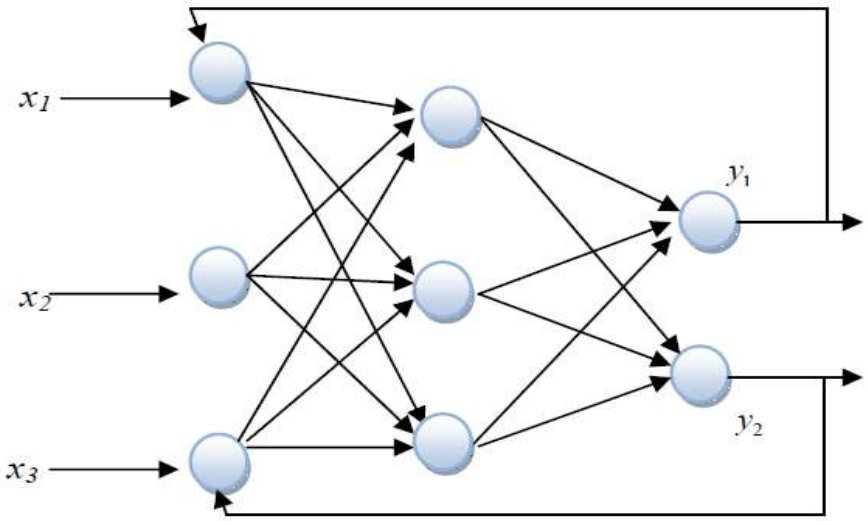


Figure II.7.Réseau bouclé [69].

II.2.7.Connexion entre les neurones :

La création des réseaux de neurones artificiels repose sur des connexions qui auront lieu en liant plusieurs entités. La connexion unidirectionnelle pondérée est considérée la connexion la plus simple [70]. Elle est sous forme d'un arc relie le neurone i au neurone j par un poids W_{ij}.

Le schéma d'une connexion simple est indiqué sur la figure (II.8).

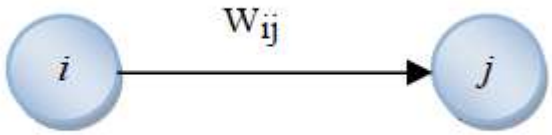


Figure .II.8. le neurone amont, j le neurone aval et W_{ij} le poids de la connexion [69] .

II.2.8. Réseau de neurones artificiel de perceptron multicouches (type feedfoward) :

Les réseaux de neurones de type feedforward (MLP) ont introduit par Rumelhart en 1986 et, simultanément, sous une appellation voisine, selon Le Cun en1985 [71]. Ils ont très appliqués dans le domaine de la simulation et de prédiction car ils ont la capacité de modéliser les processus non linéaire.

La structure d'un réseau de neurone de type feedforward est montrée sur la figure (II.10), elle est constituée essentiellement d'une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Pour ce type, le neurone dans la couche cachée ou dans la couche de sortie joue deux rôles [72] :

– Il additionne le biais aux entrées pondérées de plusieurs connexions et applique ensuite une fonction d'activation à cette somme donnée par l'équation (II.1) (pour le neurone 1de la couche cachée de la figure II.10) [67] :

$$Z_1 = f\ (\Sigma_{K=1}^{K} w_{i(s.k)} In_k + b_{1(s)}) \qquad \text{(II.1)}$$

- Il propage la valeur résultante par les connexions partantes aux normes de la couche suivante ou elle subit le même processus comme il est donné par l'équation II.2 (par exemple la sortie Y) [67] .

$$\mathrm{Y} = \mathrm{g}\ (\Sigma_{s=1}^{s} w_{0(l.s)} Z_1 + b_{2(l)}) \qquad \text{(II.2)}$$

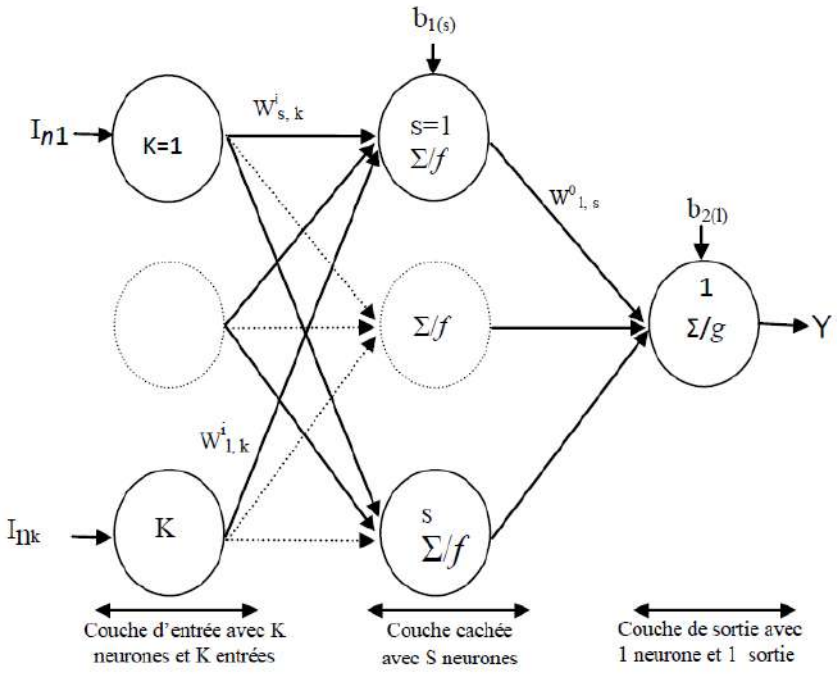


Figure II.9. Topologie d'un réseau de neurone de type feedfoward [72**].**

En conclusion, la modélisation neuronale a pour objectif de minimiser les erreurs entre les sorties expérimentales et celles prédites par le réseau [3].

II.2.9. Fonctions d'activations :

Plusieurs fonctions d'activation s'offrent à nous. Étant donné que le but de ce perceptron est de classifier, on veut que la variable de sortie soit comprise entre 0 et 1 : si la sortie est proche de 1 ("proche" est à définir selon le contexte), on dira que le neurone de sortie est actif, si la sortie est proche de 0, il sera dit inactif (d'où le terme de fonction d'activation). Dans la pratique, on adopte des fonctions comme la fonction de Heaviside, la sigmoïde logistique, la tangente hyperbolique (renormalisée par la suite pour que l'on se situe dans l'intervalle [0; 1]) encore signe doux :

Heaviside	$f(x) = 0$ si $x < 0$, 1 si $x > 0$
Sigmoïde logistique	$f(x) = \frac{1}{1+e^{-x}}$
Tangente Hyperbolique	$f(x) = \frac{2}{1+e^{-2x}} - 1$
Signe doux	$\frac{x}{1+\|x\|}$

II.2.10. Choix de la structure du réseau :

Les réseaux de neurones de perceptrons multicouches ont les caractéristiques suivantes:

– Constituent d'une ou plusieurs couches cachées

– Les neurones dans les couches cachées ou dans la couche de sortie possèdent un même modèle.

– La fonction d'activation dans la couche cachée est non linéaire tandis que dans la couche de sortie est linaire pour une régression non linéaire.

La structure de réseaux de neurone artificiel est générée par divers paramètres [67] :

– Nombre de neurone de la couche d'entrée et de sortie.

– La taille ou la dimension de l'échantillon d'apprentissage.

– La quantité de bruit dans les sorties du réseau.

– La complexité de la fonction ou de la classification à faire apprendre au réseau.

– L'architecture du réseau.

– modèle de fonction d'activation des neurones cachés.

– L’algorithme d’apprentissage.

– La régularisation .

II.2.11. Apprentissage des réseaux de neurones :

Le point crucial du développement d’un réseau de neurones est son apprentissage. Il s’agit d’une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d’information [73]. Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage montre en effet peu d'intérêt.

Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience. Les poids sont initialisés avec des valeurs aléatoires. Puis des exemples expérimentaux représentatifs du fonctionnement du procédé dans un domaine donné, sont présentés au réseau de neurones. Ces exemples sont constitués de couples expérimentaux de vecteurs d’entrée et de sortie. Une méthode d’optimisation modifie les poids au fur et à mesure des itérations pendant lesquelles on présente la totalité des exemples, afin de diminuer l’écart entre les sorties calculées et les sorties expérimentales. Afin de prévenir les problèmes de sur apprentissage, la base d’exemples est divisée en deux parties : la base d’apprentissage et la base de test. L’optimisation des poids se fait sur la base d’apprentissage, mais les poids retenus sont ceux pour lesquels l’erreur obtenue sur la base de test est la plus faible. En effet, si les poids sont optimisés sur tous les exemples de l’apprentissage, on obtient une précision très satisfaisante sur ces exemples mais on risque de ne pas pouvoir généraliser le modèle à des données nouvelles. A partir d’un certain nombre d’itérations, le réseau ne cherche plus l’allure générale de la relation entre les entrées et les sorties du système, mais s’approche trop prés des points et « apprend » le bruit.

L’erreur sur la base de test diminue puis augmente à partir d’un certain nombre d’itérations. Les poids retenus sont ceux qui minimisent l’erreur sur la base de test.

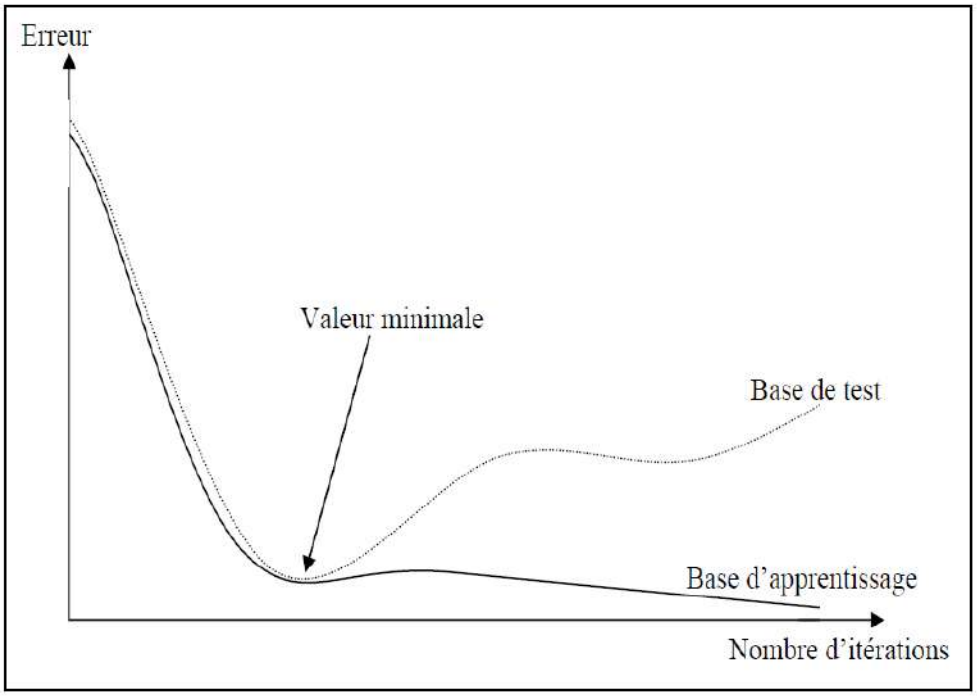


Figure II.10. Erreur moyenne sur la base d'apprentissage en fonction du nombre d'itérations [73].

Les architectures des réseaux neuronaux les plus appliqués sont des architectures à retro propagation avec une ou plusieurs couches cachées avec l'application de l'algorithme d'apprentissage de Levenberg- Marquardt [74].

Les performances du réseau neuronal ont été calculées en terme de la racine carrée de l'erreur quadratique moyenne (REQM) et le coefficient de corrélation (R^2) dont les expressions sont données par les relations suivantes [75] :

$$\mathbf{REQM}=\sqrt{\frac{\mathbf{1}}{\boldsymbol{p}}\Sigma_{\boldsymbol{q=1}}^{\boldsymbol{P}}[(\boldsymbol{Y})_{\boldsymbol{q}}^{\boldsymbol{exp}}-(\boldsymbol{Y})_{\boldsymbol{q}}^{\boldsymbol{predit}}]^{\mathbf{2}}} \qquad \text{(II. 3)}$$

$$\mathbf{R}^2=1-\frac{\Sigma_{\boldsymbol{q}}^{\boldsymbol{P}}[(\boldsymbol{Y})_{\boldsymbol{q}}^{\boldsymbol{exp}}-(\boldsymbol{Y})_{\boldsymbol{q}}^{\boldsymbol{predit}}]^{\mathbf{2}}}{\Sigma_{\boldsymbol{q}}^{\boldsymbol{P}}[(\boldsymbol{Y})_{\boldsymbol{q}}^{\boldsymbol{exp}}-(\boldsymbol{Y})_{\boldsymbol{n}}]^{\mathbf{2}}} \qquad \text{(II. 4)}$$

Ou, q est le nombre des points des données,$(Y)^{exp}$ est la sortie expérimentale et $(Y)^{predit}$ est la sortie prédite par le RNA [75].

II.3. ANFIS

II.3.1. Introduction :

Les systèmes Neuro-Flous permettent de combiner les avantages de deux techniques complémentaires. Les systèmes flous fournissent une bonne représentation des connaissances. L'intégration de réseaux de neurones au sein de ces systèmes amende leurs performances grâce à la capacité d'apprentissage de réseaux de neurones. Inversement, l'injection des règles floues dans les réseaux de neurones, souvent critiques pour leur manque de lisibilité, clarifie la signification des paramètres du réseau et facilite leur initialisation, ce qui représente un gain de temps de calcule considérable pour leur identification.

De nombreux types de systèmes Neuro-flous ont été définit et développée ces dernières années, loin d'être uniformiser, et parfois équivoque et confuse. Afin de clarifie les définitions, nous proposons dans ce chapitre une présentation bref des quelques types des systèmes Neuro-flous et présentation plus détailler de L'ANFIS.

II.3.2. Définition :

Le système Neuro-Flous se reporte à la manière d'appliquer de diverses méthodes d'apprentissage développer à la littérature de réseau de neurone aux systèmes d'inférence flou.

Le système neuro-flous est un système multicouche qui comprend les éléments de base et les fonctions habituelles des systèmes de commande avec la logique floue.

Grâces à leurs capacités d'étude intrinsèque, la puissance de calcul numérique, la tolérance aux pannes et la bonne adaptabilité, ces systèmes ont été appliqués avec succès aux différentes applications.

II.3.3. Avantages et inconvénients de la logique floue et des RNA :

L'utilisation conjointe des RN et de la logique floue, permet de tirer les avantages des deux méthodes : les capacités d'apprentissage de la première et la lisibilité et la souplesse de la seconde.

Afin de résumer l'apport du neuro-flou, le tableau II.3.1 regroupe les avantages et les inconvénients de la logique floue et des réseaux de neurones.

Les systèmes neuro-flous sont créés afin de synthétiser les avantages et de surmonter les inconvénients des réseaux neuronaux et des systèmes flous. De cette manière, les algorithmes d'apprentissage peuvent être employés pour déterminer les paramètres des systèmes flous.

Ceci revient à créer ou amender un système flou de manière automatique, au moyen des méthodes spécifiques aux réseaux neuronaux [76].

Tableau II.3.1. Comparaison entre la logique floue et les RNA.

Réseaux de neurones (RN)	**Logique floue**
Avantages	
– Le modèle mathématique non requis. – Aucune connaissance basée sur les règles. – Plusieurs algorithmes d'apprentissage sont disponibles.	– Le modèle mathématique non requis. – La connaissance antérieure sur les règles peut être utilisée.
Inconvénients	
– Boite noire. – L'adaptation aux environnements et le réapprentissage est souvent obligatoire. – Aucune garantie sur la convergence de l'apprentissage.	– Les règles doivent être disponibles. – Ne peut pas apprendre – Adaptation difficile au changement de l'environnement. – Aucune méthode formelle pour l'ajustement (par tâtonnement).

II.3.4. Les différentes combinaisons neuro-floues :

Il existe quatre grandes catégories de combinaisons des réseaux de neurones avec la logique floue[76].

II.3.4.1 . Réseau flou neuronal :

Des techniques floues sont utilisées pour augmenter les possibilités d'apprentissage ou l'exécution d'un réseau neuronal. Ce genre d'approche ne doit pas être confondu avec les approches mixtes.

II.3.4.2. Modèles neuro-flous coopératifs :

Le réseau neuronal est employé pour déterminer les paramètres (les règles et les ensembles flous) d'un système flou. Après la phase d'apprentissage, le système flou fonctionne sans réseau neuronal. C'est une forme simple des systèmes neuro-flous.

II.3.4.3. Modèles neuro-flous hybrides :

Un réseau neuronal et un système flou sont combinés dans une architecture homogène. Le système peut être commenté comme un réseau neuronal spécial avec des paramètres flous ou comme un système flou mis en application sous une forme distribuée parallèle.

II.3.5. Optimisation d'un Système d'Inférence Floue :

L'optimisation d'un SIF se dissocier en deux sous-problèmes [77] :

- **Optimisation structurelle**

Il s'agit de déterminer le nombre optimal des règles, le nombre des fonctions d'appartenance pour chaque variable, les opérateurs de conjonction, de disjonction et d'implication, la technique de défuzzification.

- **Optimisation paramétrique**

Une fois la structure est choisie, le problème est le placement optimal des fonctions d'appartenance d'entrée et de sortie, les paramètres définissant les sorties des règles.

Citons quelques méthodes d'optimisation :

- Méthode de descente du gradient.
- Méthode de Newton.
- Le Recuit simulé.
- Broyden-Fletcher-Goldfard-Shanno (BFGS).
- Les Algorithmes génétiques 6. Méthode des moindres carrés.

Le choix d'un algorithme d'optimisation est un composant critique dans l'efficacité d'une architecture floue. On demande en général à un tel algorithme un certain nombre de propriétés par exemple : Il faut qu'il soit efficace, c'est-à-dire qu'il permette d'atteindre la meilleure solution en un temps acceptable ; et sa mise en œuvre doit être la plus simple possible.

II.3.6. Description des réseaux Neuro-Flou utilisés ANFIS (Adaptative neuro-fuzzy inference systems) :

C'est un système d'inférence adaptatif neuro-flou qui consiste à utiliser un réseau neurone de type MLP à 5 couches pour lequel chaque couche correspond à la réalisation d'une étape d'un système d'inférence floue de type Takagi-Sugeno. Pour la simplicité, nous supposons que le système d'inférence flou à deux entrées X_1 et X_2, et à comme une sortie **f**. Supposer que la base de principe contient deux principes floues de type Takagi-Sugeno.

$$\text{Règle}_1 : \text{SI } X_1 \text{ est } \boldsymbol{M_1} \text{ et } X_2 \text{ est } \boldsymbol{L_1} \text{ ALORS } f_1 = p_1 X_1 + q_1 X_2 + r_1 \qquad \text{(II. 5)}$$

$$\text{Règle}_2 : \text{SI } X_1 \text{ est } \boldsymbol{M_2} \text{ et } X_2 \text{ est } \boldsymbol{L_2} \text{ ALORS } f_2 = p_2 X_1 + q_2 X_2 + r_2 \qquad \text{(II. 6)}$$

L'ANFIS à une architecture posée par cinq couches comme représenté sur la figure (II.11)

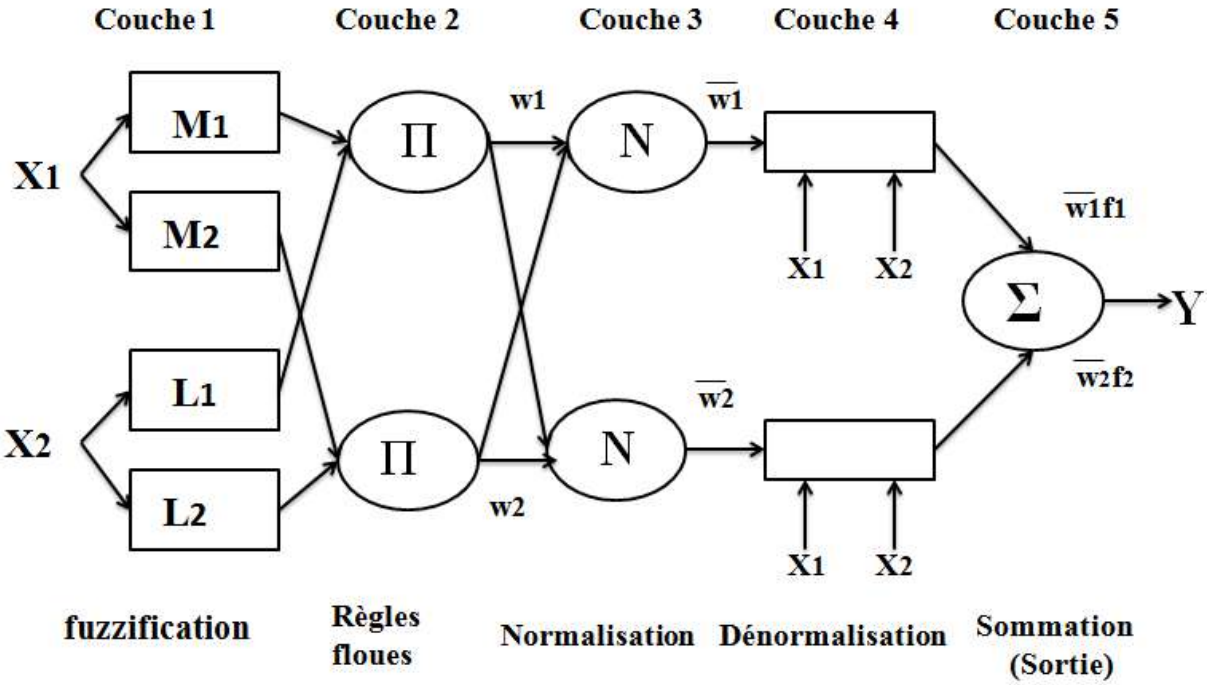


Figure II.11 : Architecture d'ANFIS.

Première couche

La première couche d'une architecture de type ANFIS comporte autant de neurones qu'il y'a de sous-ensembles flous dans le système d'inférence représenté. Chaque neurone calcule le degré de vérité d'un sous ensemble flou particulier par sa fonction de transfert. La seule restriction sur le choix de cette fonction concerne sa dérivabilité. En retrouve dans la littérature, l'utilisation, de fonctions gaussiennes et les paramètres modifiables sont le centre et la pente de la gaussienne (variance). La fonction d'activation des neurones *i* de la première couche :

$$f_i^1 = U_{Ai}(x) \qquad \text{(II.7)}$$

Avec X_i est l'entrée au neurone *"i"*, et *Mi* ,L_i est un sous ensemble floue correspondant au variable X_i. En d'autres termes, f_i^1 est la fonction d'appartenance du *Mi* ,L_i et il indique le degré auquel donné X_i satisfait le quantifier *Mi* ,L_i. Nous choisissons $U_{Ai}(x)$ pour être en forme de (Gaussien, triangle, trapézoïdal) avec le maximum égal à 1 et le minimum égal à 0, tel que les fonctions généralisées de ces formes sont :[78]

$$Triangle : U(x) = \max\left(min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \qquad \text{(II.8)}$$

$$Trapézoidale : \ U(x) = \max\left(min\left(\frac{x-a}{b-a}, 1, \frac{c-x}{c-b}\right), 0\right) \qquad \text{(II.9)}$$

$$Gaussienne: U(x) = \exp\left(-\frac{(x-c)^2}{\sigma^2}\right) \quad \text{(II.10)}$$

Où $\{a, b, c, \sigma\}$ est l'ensemble des paramètres. Pendant que les valeurs de ces paramètres changent, les fonctions en forme précédente changent en conséquence, de ce fait présenter de plusieurs formes de fonction d'appartenance sur la variable linguistique *Mi* ,L_i. Les paramètres dans cette couche désignés sous le nom des paramètres de fonction d'appartenance [78].

Deuxième couche cachée

La deuxième couche cachée sert à mesurer le degré d'activation des prémisses. Les neurones de ces couches représentent chacun la prémisse d'une règle. Ils reçoivent en entrée le degré de vérité des différents sous-ensembles flous composant cette prémisse et ont en charge le calcul de son propre degré de vérité. Les fonctions d'activation utilisées pour ces neurones dépendant des opérateurs présents dans les règles (ET ou OU). La fonction d'activation des neurones ***i*** de la première couche : W = μ (x) μ (y)

$$w_k = U(X)\ U(Y) \quad \text{(II.11)}$$

Ou *k* : représente le nombre de règle, *i* : représente le nombre de partition de *x*, et *j* : le nombre de partition de y [78].

Troisième couche

La troisième couche cachée normalise de degré d'activation des règles. Chaque neurone dans cette couche est un neurone de cercle noté N. le i^{ème} neurone mesure le rapport entre i^{ème} poids de règles et la somme de tous les poids des règles. Cette opération est notée la normalisation des poids.

$$\overline{W_k} = \frac{W_k}{\sum w_i} \quad \text{(II.12)}$$

L'ensemble des sorties de cette couche seront appelées les poids normalisés.

Quatrième couche

La quatrième couche cachée sert à déterminer les paramètres la partie conséquence des règles (*p* ,*q*, *r*). La fonction de chaque neurone dans cette couche est la suivante

$$f_k^4 = \overline{W}_k \times f_k = \overline{W}_k \times (p_k X1 + q_k X2 + r_k) \quad \text{(II.13)}$$

Où $\overline{W}_k$est la sortie de la troisième couche, et $(p_k X1 + q_k X2 + r_k)$ est l'ensemble des paramètres. Ces paramètres marquer sous le nom les paramètres conséquents.

Cinquième couche

La couche de sortie contient un seul neurone dans cette couche, est un neurone de cercle noté S qui mesure la sortie globale comme addition de tous les signaux entrants, c'est-à-dire [78] :

$$f^5 = \sum_k \bar{W}_k \times f_k^4 \qquad \text{(II.14)}$$

II.4. Conclusion :

Il existe de nombreuses utilisations et fonctions possibles utilisant l'ordinateur ; développement de jeux, création de pages Web, analyse de données, recherche, calculs, etc. La programmation offre de nombreuses opportunités, le plus important étant, l'apprentissage par machine. Étant donné qu'avec suffisamment de données et un modèle d'apprentissage automatique précis, il est possible de prédire des entités délicates à estimer expérimentalement ou impossibles à accomplir. Ainsi, l'aspect le plus intéressant est l'apprentissage automatique, c'est ses applications possibles et déjà réelles.

Les algorithmes et les systèmes d'apprentissage automatique ont connu d'importantes avancées. Cette décennies, grâce à la disponibilité de grands volumes de données et du calcul intensif, sans oublier les avancées intéressantes en optimisation, une modélisation basée sur des méthodes d'apprentissage de la machine semblait prometteuse.

Tout au long de ce chapitre, des techniques d'apprentissage de la machine et algorithmes qui ferons objet d'outils pour la modélisation dans ce travail sont décrites de manière explicite.

CHAPITRE III

MATERIELS ET METHODES

III.1. Introduction :

Les colorants de synthèse, toxiques pour la plupart, sont très employés dans l'industrie textile, papier, tannage du cuir, la transformation des aliments, les plastiques et les cosmétiques. La plupart des colorants sont des composés organiques complexes qui réduisent la pénétration de la lumière du soleil dans l'eau. Ils engendrent une pollution difficile à contrôler et à mesurer. Les colorants solubles dans l'eau sont difficilement éliminés par des traitements classiques lorsqu'ils proviennent des eaux des bains de teinture.

Les méthodes physicochimiques et biologiques de traitement des eaux usées ne peuvent pas éliminer complètement les colorants. L'élimination des polluants par le procédé d'adsorption des eaux usées est la méthode la plus utilisée.

La plupart des adsorbants ont tendance à éliminer les polluants de manière discriminante, ce qui rend difficile de récupérer sélectivement certains matériaux précieux à partir des eaux usées pour la réutilisation. En outre, une amélioration supplémentaire de la capacité d'adsorbant, la résistance mécanique et d'autres propriétés nécessitent une application large. Les polymères sont apparus comme une alternative potentielle aux adsorbants traditionnels. Ils ont une grande capacité à éliminer différents polluants organiques et inorganiques.

(Mahmoodi et al.) [79] ont synthétise l'hydroxyde de nickel β-ni$(OH)_2$, étudié ses caractéristiques physiques et sa capacité d'adsorption des colorants en utilisant le transformée de Fourier infrarouge.

A l'aide des isothermes et la cinétique d'adsorption et à partir de systèmes mono et bi-composants ils ont étudié l'effet des paramètres opérationnels telle que : le dosage de la concentration des colorants et l'adsorbant sur l'élimination des colorants dans l`eau.

Dans ce chapitre, nous allons faire une description générale de matériels employés, des méthodes de caractérisation de l'adsorbant et les adsorbats tout au long de l'adsorption mono et bi-composants. Tous les données et les résultats sont tirer directement de l'article (Mahmoodi et al.) [79].

III.2. Revue critique sur l'utilisation des RNA et ANFIS pour la modélisation de l'adsorption multi-composants :

L'adsorption des constituants liquides ou gaz par un solide est basée sur plusieurs modèles des isothermes, ces modèles sont calculées à partir des équations empiriques et semi empiriques. Le calcul devient de plus en plus lent avec l'augmentation de nombre de constituants à adsorber.

Les réseaux de neurones artificiels peuvent être utilisés pour modeler les isothermes d'adsorption pour les systèmes mono-composants et multi-composants, nous nous intéressons pour les modèles d'adsorption d'un système multi-composants.

A travers la recherche bibliographique qu'on a effectuée sur les travaux concernant la modélisation neuronale de l'adsorption multi-composants, on a remarqué que peu d'articles ont été publiés dans ce domaine, on cite à titre d'exemple :

Modélisation d'adsorption multi-composants : les isothermes pour les solutions modèles ABE en utilisant le carbone activé F-400 :

Des modèles d'isotherme ont été proposés tels que Langmuir et Freundlich multi-composants. Dans cette étude, les modèles d'isotherme ont été proposés tels que Langmuir et Freundlich ainsi que les réseaux neuronal artificiels ont été utilisés pour modéliser les isothermes de chaque composant dans un bouillon de fermentation ABE en fonction des concentrations d'équilibre de tous les composants sur le charbon actif F-400.

Les résultats ont montré que le modèle de Langmuir multi-composants n'était pas précis en raison des nombreuses hypothèses simplificatrices. Par contre pour le modèle de Freundlich multi-composants et le réseau neural feedforward (FFNN) ont donné une meilleur performance avec un coefficient de détermination R^2= 0.97 et 0.99, pour le modèle de Freundlich multi-composant et des modèles d'isotherme FFNN, respectivement.

Analyse et modélisation de l'adsorption d'un système multi-composant de métaux lourds sur les plumes de poulet en utilisant les conceptions expérimentales de Taguchi et les réseaux de neurones artificiels :

Dans cette étude, les auteurs ont utilisé une approche intégrée basée sur les conceptions expérimentales de Taguchi et les réseaux de neurones artificiels (RNAs) pour l'analyse et la modélisation d'adsorption des ions Cadmium (Cd^{2+}), nickel (Ni^{2+}) et de plomb (Pb^{2+}) à partir des solutions aqueuses en utilisant des plumes de poulet comme un adsorbant. Les résultats ont montré que le réseau de neurone artificiel avec 10 couches caché donne la meilleure performance avec un coefficient de détermination R^2= 0.97.

Simulation des systèmes multi-composants d'adsorption en phase liquide : éthanol et sucre résiduel :

Dans cette étude, des expériences ont été menées pour identifier l'adsorbant ayant le plus grand potentiel pour extraire l'éthanol de manière sélective à partir du bouillon de fermentation. Trois modèles d'adsorption concurrentielle (Langmuir étendu, Langmuir modifié et un modèle basé sur les réseaux de neurones artificiels (RNA)) ont été testés sur

l'ensemble de données expérimentales à différentes concentrations d'éthanol et de sucre et déterminé les paramètres d'isotherme pour chaque modèle.

Les résultats ont montré que le modèle de Langmuir modifié et Langmuir étendu étaient moins précis par rapport au réseau de neurone artificiel avec un coefficient de détermination R^2 = 0.85, 0.91 et 0.99, pour le modèle de Langmuir modifié, Langmuir étendu et le réseau de neurone artificiel, respectivement.

La prédiction de la tension superficielle des mélanges ternaires à différentes températures en utilisant des réseaux de neurones artificiels :

Les auteurs de ce travail ont utilisés le réseau de neurones artificiel (RNA) pour proposer un modèle pratique à fin de prédire la tension superficielle des mélanges multi-composants. Afin de développer un modèle fiable, ils ont utilisé l'ensemble de données expérimentales de 15 mélanges liquides ternaires à différentes températures. Ces systèmes se composent de 777 points de données contenant généralement des composants hydrocarbonés. La structure de ce modèle est composée de 2 couches cachées avec 6 et 5 neurones dans les première et deuxième couches cachées respectivement. Les écarts relatifs moyens relatifs à la formation, aux points de données prédits et au total ont été obtenus 1,69, 1,86 et 1,72.

Modélisation de l'adsorption des métaux lourds sur la biomasse lignocellulosique en utilisant le réseau de neurone artificiel : effets des ions métallique et les caractéristiques d'adsorbant :

Cette études est une application d'une approche de réseau de neurones pour modéliser et analyser la performance de l'adsorption de différents déchets lignocellulosique, les fruits nommer de jacaranda, les noix de prune et les coquilles de noix, pour éliminer les ions de métaux lourds (Pb^{2+} ,Cd^{2+}, Ni^{2+} et Zn^{2+}) à partir d'une solutions aqueuses.

Le réseau de neurones artificiel a été utilisé avec 4 couches caché pour déterminer la pertinence et l'importance des caractéristiques de l'adsorbant et des polluants sur la cinétique et les isothermes de l'adsorption des métaux.

Les résultats de cette étude à donner de meilleur performances avec un coefficient de détermination R^2= 0.97.

Modélisation de l'adsorption dynamique de pesticides sur filtre à charbon actif à l'aide de réseaux de neurones :

Les auteurs dans ont fait leurs études sur la modélisation des courbes de percée de filtres charbons actifs à lits fixes pour l'adsorption de pesticides, en milieux aqueux, par un modèle déterministe classique, et par deux réseaux de neurones (RN) : un réseau de neurones bouclé à trois couches ou réseau de neurones dynamique (RND) et un réseau de neurones non bouclé à

trois couches ou réseau de neurone statique (RNS). L'objectif est de modéliser le comportement de filtres industriels utilisés dans le traitement d'eau potable.

Les deux modèles statistiques (réseaux de neurones), dont l'architecture est optimisée en termes de sélection des entrées et de nombre de neurones cachés, présentent une capacité de prédiction intéressante de la globalité de la courbe de percée ($R^2 > 0,99$) et des erreurs quadratiques moyennes relativement faibles (EQM < 0,03). Cependant, le RND, avec un nombre de paramètres moins élevé dû à un plus faible nombre de variables explicatives (7 contre 11) et de neurones cachés (2 contre 7), permet une meilleure prédiction de la zone de percée que le RNS qui tend à sous-estimer les valeurs de concentration en sortie de filtre.

Modélisation de la dose de coagulant par les systèmes à base d'inference floue (ANFIS) application à la station de traitement des eaux de Boudouaou (ALGERIE)

Le présent article décrit un modèle neuro flou de type Takagi Sugeno (TK), développé pour la prédiction de la dose de coagulant utilisée lors de la phase de clarification dans la station de traitement des eaux de Boudouaou qui alimente la ville d'Alger en eau potable. Le modèle ANFIS (système d'inférence flou à base de réseaux de neurones adaptatifs), qui combine les techniques floues et neuronales en formant un réseau à apprentissage supervisé, a été appliqué durant la phase de calage et testé en période de validation. Les résultats obtenus par le modèle ANFIS ont été comparés avec ceux obtenus avec un réseau de neurones de type perceptron multicouche (MLP) et un troisième modèle à base de régression linéaire multiple (MLR). Un coefficient de détermination (R^2) de l'ordre de 0,92 en période de validation a été obtenu avec le modèle ANFIS, alors que pour le MLP, il est de l'ordre de 0,75, et que pour le modèle MLR, il ne dépasse pas 0,35.

Modélisation de l'adsorption simultanée du colorant et de l'ion métallique par sciure de solution aqueuse utilisant Ann et Anfis :

Dans cette recherche, un réseau neuronal artificiel en avant (ANN) et un système d'inférence neuro-fuzzy adaptatif (ANFIS) a été utilisé pour la prédiction de Potentiel d'adsorption de la sciure dans l'élimination simultanée d'un colorant cationique et d'un ion métallique lourd de la solution aqueuse. Cinq variables opérationnelles, concluant le colorant initial, Cu initial (II), pH, Le temps de contact et le dosage d'adsorbant ont été sélectionnés pour étudier leurs effets sur l'adsorption étude. L'application de modèles (ANN) et (ANFIS) pour des expériences a été utilisé pour Optimiser, créer et développer des modèles de prédiction pour l'adsorption de colorant et de Cu (II) en utilisant la sciure de bois de Melia Azédarach. Le résultat révèle que les modèles ANN et ANFIS comme prometteur La prédiction de la technique serait efficacement utilisée pour la simulation de l'adsorption des colorants et des ions métalliques. Selon ce résultat, dans la formation du coefficient de détermination de l'ensemble de données, a été obtenu de 0,99 et 0,98 pour la teinture et l'ion métallique, respectivement. De plus, dans l'ANFIS, le modèle R^2 a été calculé de 0,99 pour les deux polluants.

Élimination par adsorption du Pb(II) au moyen d'un nano adsorbant hybride nano composite hydroxyapatite/chitosane : modélisation ANFIS et étude expérimentale :

Dans la présente étude, l'efficacité de prédiction de l'adsorption du plomb par un adsorbant nano composite hautement fonctionnel d'hydroxyapatite (HAp)/chitosane à l'aide du système ANFIS a été étudiée. L'ANFIS a modélisé les résultats avec une erreur moyenne totale et une moyenne totale d'erreur absolue inférieures à 0,0646 % et 4,2428 %, respectivement, pour les données d'entraînement. De plus, le coefficient de détermination des données d'entraînement et des données de test s'est avéré être de 0,9999 et 0,9823, respectivement.

La conception et la mise en œuvre de l'élimination par adsorption du Cu(II) du lixiviat à l'aide d'ANFIS :

Le système d'interface floue neuronale adaptative (ANFIS) a été utilisé pour modéliser le système expérimental par lots et prédire les valeurs d'entrée optimales, c'est-à-dire le pH initial, le dosage de l'adsorbant et le temps de contact. Les résultats de la modélisation ANFIS suggérée ont ensuite été comparés à un plan expérimental factoriel complet (23), Les résultats montrent que la clinoptilolite est un adsorbant efficace et un ANFIS, facile à mettre en œuvre et capable de modéliser le système expérimental batch.

III.3. Base de données :

La base de données comprend les paramètres expérimentaux suivant : (Masse moléculaire, Concentration initial des colorants, masse de l'adsorbant, temps d'adsorption, quantité adsorbée en %), est constituée des données expérimentales de différentes courbes de percées représentant la quantité adsorbée en fonction de temps sous différents conditions opératoires, pour deux systèmes : mono-composant et bi-composants. Cette base est tiré directement à partir de l'article (Mahmoodi et al.) [79] .

III.3.1. Choix des paramètres d'entrées et de sorties :

Afin de rassembler les deux systèmes mono-composants et bi-composants, on a choisi comme des paramètres comme suit :

- **Paramètres d'entrées :** (Masse moléculaire, la concentration des colorants, masse d'adsorbant et le temps d'adsorption) tel que :

- Masse moléculaire $_i$: La masse moléculaire pour chaque composé.
- La concentration des colorants $_i$ = (20 mg/l, 40 mg/l, 60 mg/l, 80 mg/l).
- m : La masse d'adsorbant = (0.0125g, 0.025g, 0.05g, 0.075g, 0.1g, 0.2g, 0.3g).
- t : Le temps d'adsorption (2.27 min - 60 min).

Ce qui construit une matrice de 6 colonnes et 400 lignes.

- **Paramètres de Sortie** (quantité adsorbée pour les 03 colorants désignée par "q_{ei}") tel que :

- (q_{e1}), quantité adsorbée de premier colorant varie de 0 et 100%.
- (q_{e2}), quantité adsorbée de deuxième colorant varie de 0 et 100%.
- (q_{e3}), quantité adsorbée de troisième colorant varie de 0 et 100%.

Ce qui donne une matrice de 1 seule colonne et 400 lignes.

III.3.2. Préparation de la base de données :

La base de données d'entrée est réalisée par une matrice rectangulaire de dimension (400, 6), répartie de la façon suivante (voir tableau III.2) :

Tableau III.1. Répartition de la base de données d'entrés.

Ligne : 0-132	La variation de l'adsorption du colorant d'un système mono-composant en fonction de la variation de la masse d'adsorbant.
Ligne ; 133-308	La variation de l'adsorption du colorant d'un système bi-composant en fonction de la variation de la masse d'adsorbant.
Ligne : 309-400	La variation de l'adsorption du colorant d'un système mono-composant en fonction la variation de la concentration initiale des colorants.

La base de sortie est réalisée par un vecteur de dimension (400,1) répartie de la façon suivante (voir tableau III.3) :

Tableau III.2. Répartition de la base de données de sortie.

Ligne : 0-132	La variation de la quantité adsorbée du colorant d'un système mono-composant en fonction de la variation de la masse d'adsorbant.
Ligne : 133-308	La variation de la quantité adsorbée du colorant d'un système bi-composant en fonction de la variation de la masse d'adsorbant.
Ligne : 309-400	La variation de la quantité adsorbée du colorant d'un système mono-composant en fonction la variation de la concentration initiale des colorants.

La base des données ainsi constituée est divisée en trois sous - bases :

- Une base d'apprentissage qui permet l'optimisation de l'architecture de RNA et ANFIS
- Une base de test utilisée pour déterminer les performances prédictives des modèles du RNA et ANFIS.
- Une base de validation utilisée pour déterminer les performances prédictives des modèles du RNA et ANFIS.

III.3.3. Etude statistique des paramètres influençant de l'adsorption et le taux des concentrations des colorants :

L'adsorption des colorants et leurs paramètres influençant sont associés les uns aux autres dans une relation complexe, faisant de la modélisation de la qualité de l'eau un processus plus complexe. Par conséquent, les données d'entrée (paramètres physique) du modèle doivent être déterminées au départ. Dans cette modélisation, la méthode d'analyse de corrélation, terme

désignant les significations d'une relation entre deux ou plusieurs variables, est appliquée pour définir la structure des paramètres d'entrées. Les résultats de l'analyse de corrélation des variables d'entrée sont présentés dans la figure III.13. Il montre que toutes les variables ont une faible corrélation mutuelle. Par conséquent, les paramètres physiques influencent, à savoir la Masse moléculaire, la concentration des colorants, masse d'adsorbant et le temps d'adsorption sont choisies comme des variables d'entrée. L'évolution du contenu d'adsorption des colorants par β-$Ni(OH)_2$, en plus les paramètres physiques d'adsorption, sont caractérisées par les paramètres statistiques. Les statistiques descriptives sont utilisées pour décrire quantitativement ou résumer les caractéristiques des données afin d'expliquer davantage leur implication. Le taux d'adsorption des concentrations moyennes, les teneurs extrêmes (maximum et minimum) et les variations statistiques descriptives des données sur le taux d'adsorption et les paramètres physiques d'adsorption sont résumées dans le tableau III.4

Tableau III.3 : Description statistique de l'ensemble des données.

Catégorie des variables	Variables	Unité	Plages des variables (min - max)	Moyenne	STD	Variances	Kurtosis
Les entrées	Molecular Weight	(g/mol)	401-482	440.6	35.10	1232.12	-1,7285
	$[dye\ 01]_o$	(mg/L)	0-80	11	16.11	259	8,0747
	$[dye\ 02]_o$	(mg/L)	0-80	9	16.72	279	7,8171
	$[dye\ 03]_o$	(mg/L)	0-80	9	16.72	279	7,8171
	masse de β-$Ni(OH)_2$	(g)	0.0125-0.3	0.0653	0.0547	0.003	7,6301
	Temps	(min)	2.275 - 60.264	23.80	19.001	360.16	-0,9879
La sortie	% dye removal	(%)	4.375-93.364	53.73	24.46	596.902	-1,1355

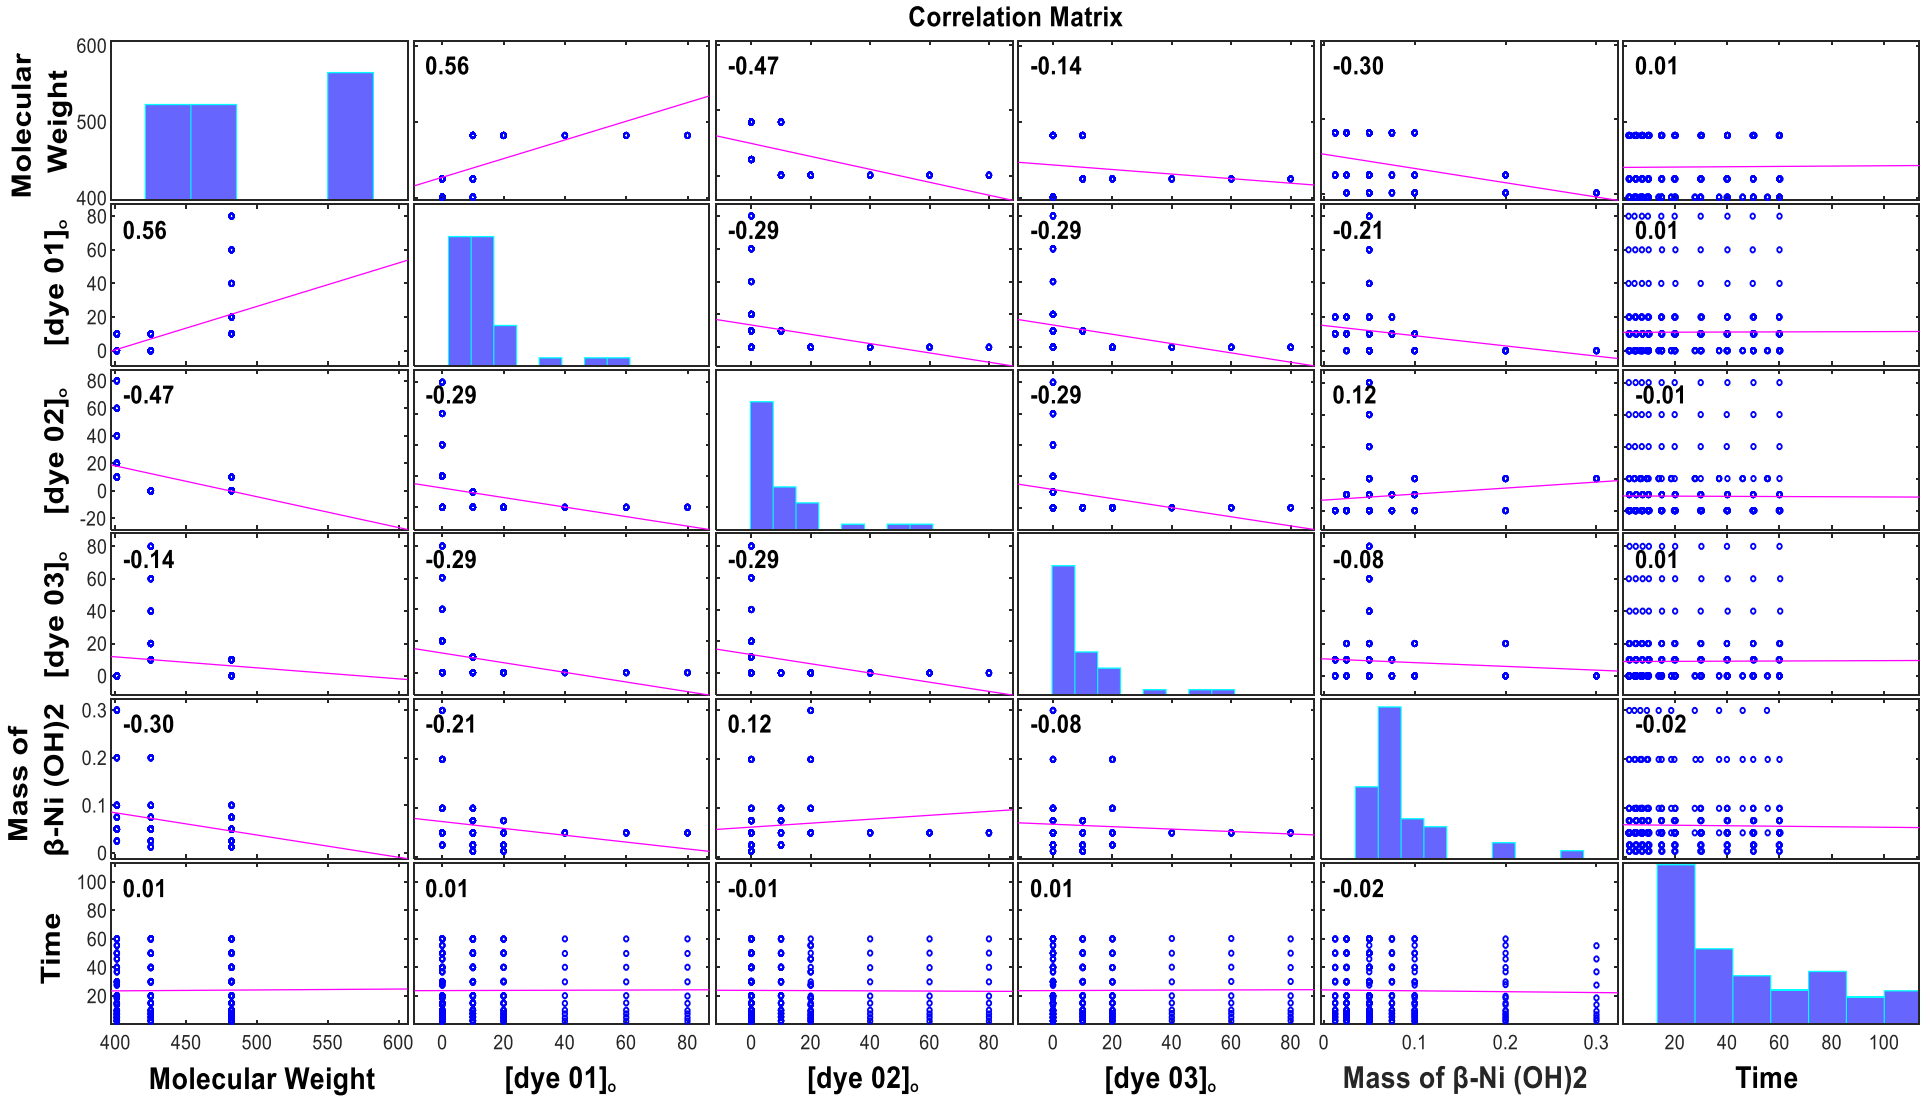


Figure III.1 : Analyse de corrélation des données d'entrée pour les modèles prédictifs.

III.3.4. Normalisation des données :

Les données sont réparties en sept colonnes, correspondant respectivement aux : {Masse moléculaire, la concentration des colorants, masse d'adsorbant, le temps d'adsorption et le pourcentage d'adsorption}.

Les valeurs numériques ont été normalisées afin d'améliorer l'optimisation. La normalisation se fait par ligne, chaque paramètre des entrées et de sorties (x_i) est normalisé (x_{inor}) par l'expression (Premnmx de MATLAB) suivante :

$$x_{in} = 2\,\frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} - 1 \qquad \text{(III.1)}$$

III.3.5. Dé-normalisation des données :

Les valeurs numériques seront tous dé-normalisées afin de représente ces valeurs a leurs état réelle, chaque paramètre d'entrées et de sorties (x_{inor}) est transformé en (x_i) par l'expression (Postmnmx sur MATLAB) :

$$x_i = 0.5 * (x_{in} + 1) * (\max(x_i) - \min(x_i)) + \min(x_i) \qquad \text{(III.2)}$$

L'apprentissage supervisé est retenue dans cette étude, il consiste à fournir au réseau des jeux de données pour lesquels on connait les réponses souhaitées.

On construit alors un critère d'erreur en comparant la réponse des modèles des RNA et ANFIS à celle attendue des valeurs de {(q_{e1}, q_{e2}, q_{e3}) expérimentale}.

III.4. Développement de réseau de neurone artificiel :

III.4.1. Choix des paramètres de RNA :

Les réseaux de neurones de type feedforward (FFNN) sont très utilisés dans le domaine de modélisation et de prédiction car ils ont la capacité de modéliser les processus non linéaire.

Nous avons programmé le RNA avec une couche cachée et deux couches cachées. Après une comparaison entre les erreurs de chaque structure, on a choisi de travaillé avec deux couches cachée (tableau III.5) et la fonction **newff,** qui correspond au RN de type FFNN et avec l'algorithme d'apprentissage de Levenberg- Marquardt (la fonction **trainlm** de MATLAB®). La fonction sigmoïde tangente hyperbolique (fonction **tansig** de MATLAB®) a été utilisée dans les couches cachées, et la fonction linéaire (fonction **purelin** de MATLAB®) pour la couche de sortie.

La structure du RNA optimisée pour l'adsorption bi-composante est résumée dans le tableau III.5.

Tableau III.4 : Structure du RNA optimisé pour l'adsorption bi-composant.

<table>
<tr><td></td><td>Type du réseau</td><td>Algorithme d'apprentissage</td><td>Couche Entrée</td><td colspan="5">Couche Cachée</td><td>Couche Sortie</td></tr>
<tr><td rowspan="3">Une seule couche</td><td rowspan="3">FFNN-BP (Fonction newff de MATLAB®)</td><td rowspan="3">Levenberg-Marquardt. (Fonction trainlm de MATLAB®)</td><td rowspan="2">Nb. De neurones</td><td>Paramétrés</td><td colspan="2">Couche Cachée 1</td><td>R</td><td>R²</td><td rowspan="2"></td></tr>
<tr><td>Nb. de neurones</td><td colspan="2">13</td><td>0.92</td><td>0.84</td></tr>
<tr><td>6</td><td>Fonction d'activation</td><td colspan="4">(Fonction tansig de MATLAB®).</td><td>(Fonction purelin de MATLAB®).</td></tr>
<tr><td rowspan="3">Deux couches cachées</td><td rowspan="3">FFNN-BP (Fonction newff de MATLAB®)</td><td rowspan="3">Levenberg-Marquardt. (Fonction trainlm de MATLAB®)</td><td rowspan="2">Nb. De neurones</td><td>Paramétrés</td><td>Couche Cachée 1</td><td>Couche Cachée 2</td><td>R</td><td>R²</td><td>Couche Sortie</td></tr>
<tr><td>Nb. de neurones</td><td>11</td><td>4</td><td>0.92</td><td>0.85</td><td>1</td></tr>
<tr><td>6</td><td>Fonction d'activation</td><td>(Fonction tansig de MATLAB®).</td><td colspan="3">(Fonction tansig de MATLAB®).</td><td>(Fonction purelin de MATLAB®).</td></tr>
</table>

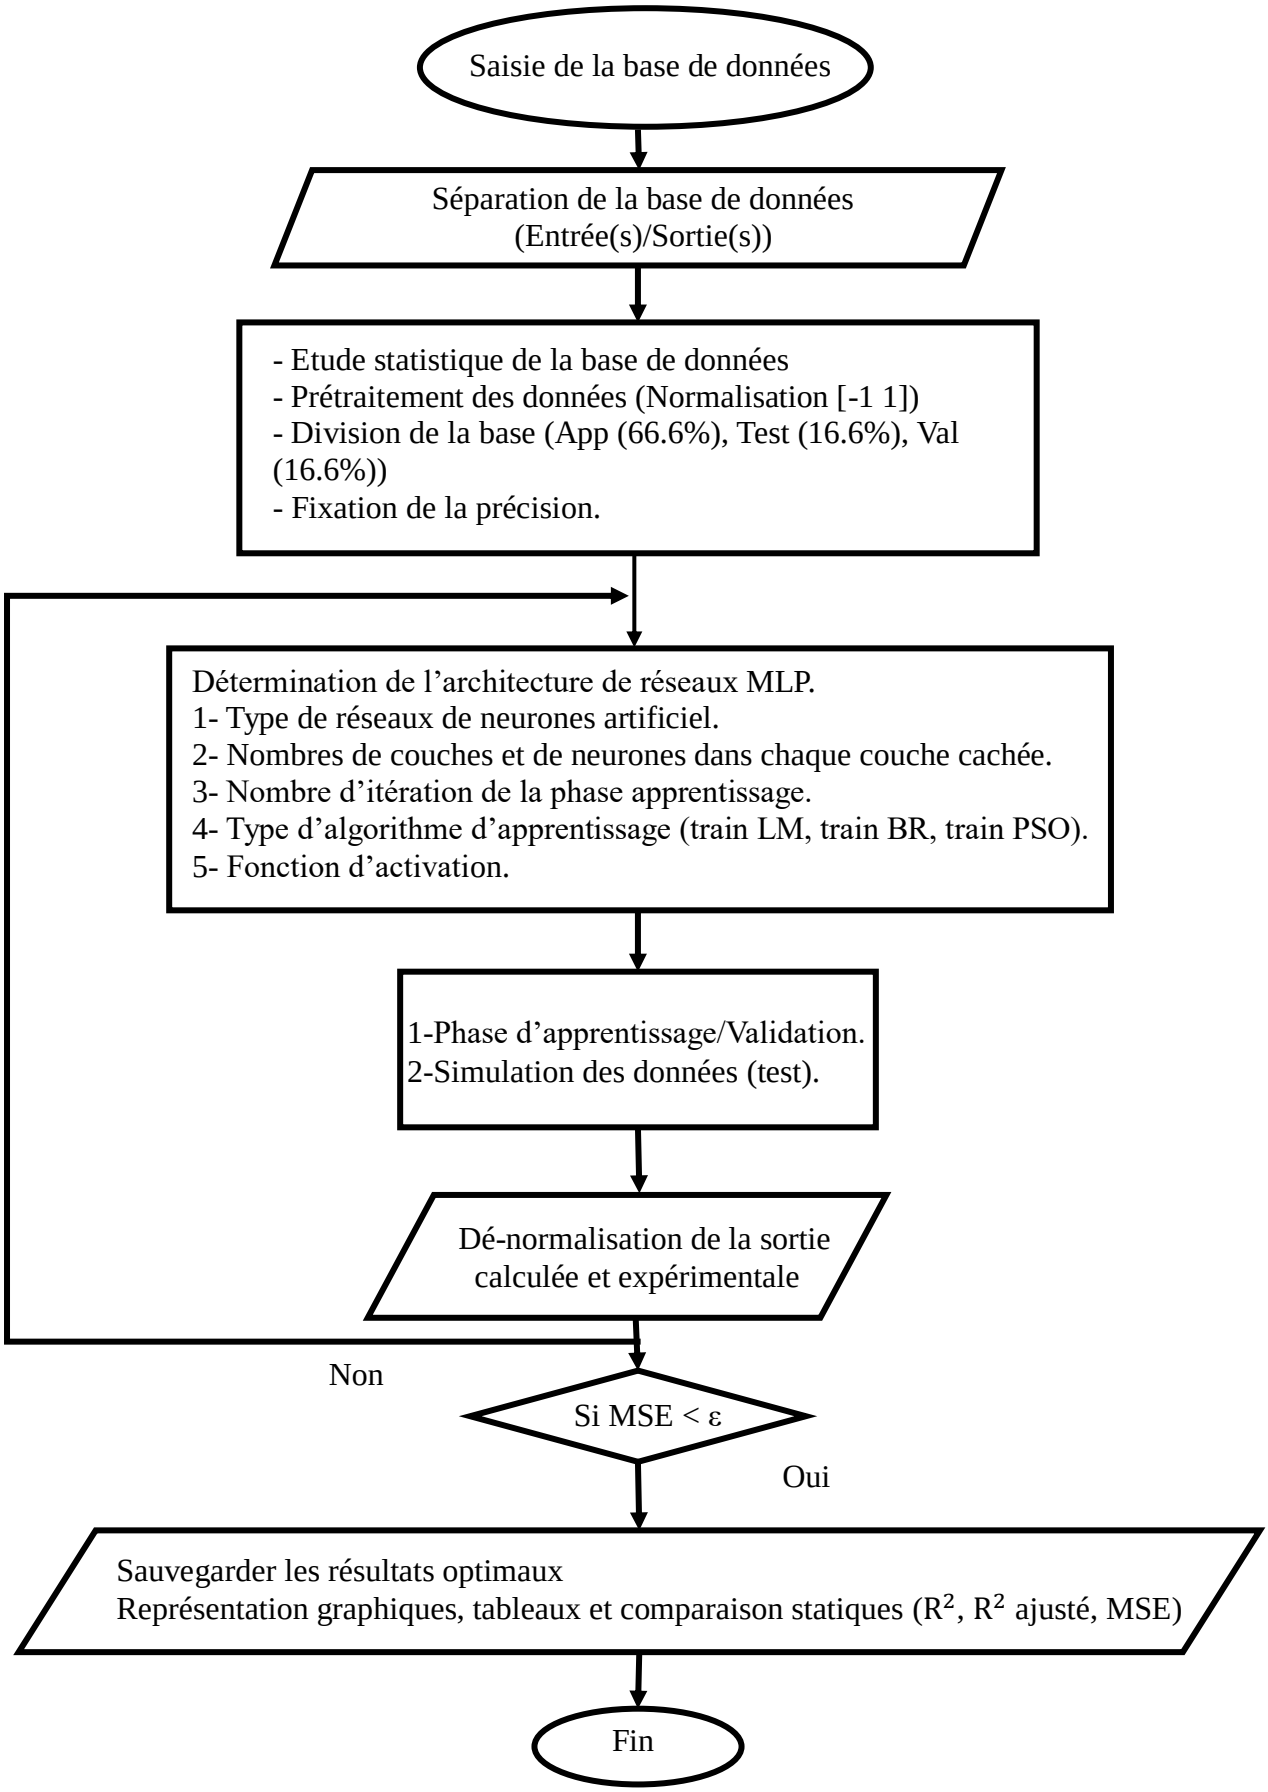


Figure III.2 : Organigramme de la méthodologie de calcul du RNA.

III.5. Modélisation de l'adsorption des colorants par l'ANFIS :

III.5.1. La méthodologie de modélisation par l'ANFIS :

L'ANFIS est très utiliser dans le domaine de modélisation et de prédiction car ils ont la capacité de modéliser les processus non linéaire (complexe).

La structure de l'ANFIS est constituée de cinq couches, chacune comportant plusieurs nœuds. Les nœuds carrés (adaptatifs) contiennent des paramètres, alors que les nœuds circulaires (fixes) n'ont pas de paramètres dans le système.

Il est basé sur les règles floues « Si.....Alors » de Takagi et Sugeno (TAKAGI et SUGENO, 1985).

Pour le cas des deux variables d'entrée x_1 et x_2 données à titre d'exemple avec la seule variable de sortie Y, chaque variable d'entrée est décrite par deux termes linguistiques : M_1 et M_2 pour la variable x_1, L_1 et L_2 pour la variable x2, respectivement, d'où une base de règle « Si.....Alors » décrite par deux règles floues R1 et R2 :

$$R_1 \text{ Si } X1 \text{ est } M_1 \text{ et } X_2 \text{ est } L_1 \text{ Alors } y=f_1(x)$$

$$R_2 \text{ Si } X1 \text{ est } M_2 \text{ et } X_2 \text{ est } L_2 \text{ Alors } y=f_2(x)$$

$$f_1(x)=p_1x_1+q_1x_2+r_1$$

$$f_2(x)=p_2x_1+q_2x_2+r_2$$

avec (p_i ; q_i ; r_i) sont des paramètre de la partie conclusion à ajuster durant l'apprentissage.

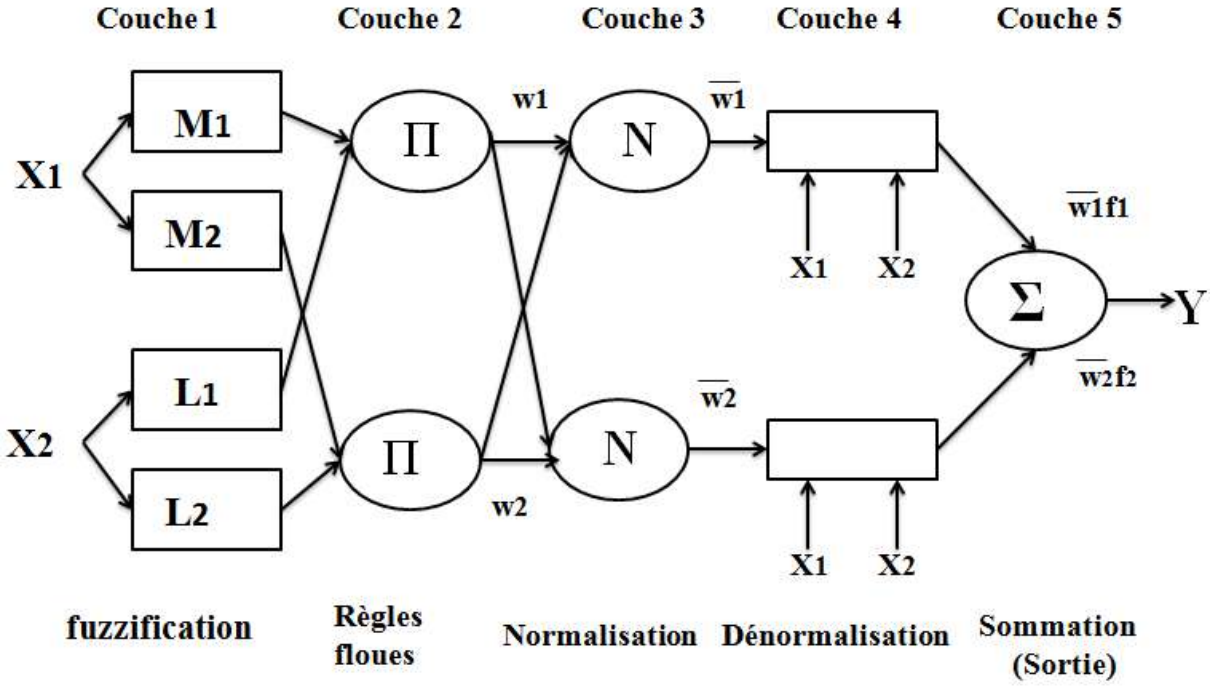


Figure III.3 : Architecture du modèle ANFIS.

-Couche 1 : Les noeuds de cette couche représentent le degré d'appartenance de x_1 (ou x_2) à Mi (ou Li); c'est la phase de fuzzification.

-Couche 2 : appelé (Π), qui reçoit les sorties des noeuds de fuzzification et calcule leur activation. Le nombre de nœuds dans cette couche est égal au nombre de règles « Si…..Alors » dans le système d'inférence flou.

- Couche 3 : appelé (N).C'est la couche de normalisation dans laquelle chaque nœud calcule le degré d'appartenance normalisé à une règle floue donnée.

Le résultat obtenu représente la participation de chaque règle floue au résultat final. Cette couche renvoie des sorties normalisées de défuzzification.

- Couche 4 : Cette Couche correspond à l'entrée initiale pondérée par le degré d'appartenance normalisé de la règle floue. C'est la phase de défuzzification.

- Couche 5 : composée d'un seul nœud fixe circulaire appelé (Σ) qui reçoit la somme des sorties de tous les noeuds de défuzzification, et fournit la sortie du modèle ANFIS.

L'algorithme d'apprentissage hybride est une association de la méthode de descente de gradient de l'erreur et de la méthode d'estimation des moindres carrés. La méthode de descente de gradient de l'erreur permet d'ajuster les prémisses alors que la méthode LSM (Least Square Method) ajuste les paramètres linéaires (conséquents ou conclusions). L'apprentissage se fait de façon itérative jusqu'à ce que le nombre de cycles d'apprentissage soit atteint ou jusqu'à ce que l'erreur moyenne entre la valeur de sortie désirée et générée par l'ANFIS atteigne une valeur prédéterminée. Cette phase dépend donc de la qualité de l'ensemble des données.

CHAPITRE IV

RÉSULTATS EXPÉRIMENTAUX

IV.1. Introduction :

L'intelligence artificielle joue un rôle majeur dans la modélisation, et par conséquent, dans notre travail, nous avons étudié deux types de méthodes d'intelligence artificielles, à savoir, le RNA et ANFIS, dans le processus d'adsorption qui vise à éliminer les colorants.

Dans ce chapitre, nous avons présenté et discuté des résultats obtenues par les deux modèles utilisés ainsi que la comparaison entre eux.

IV.2. Résultats et discussion par RNA :

Dans notre travail on exploite la technique de RNA, en utilisant le logiciel MATLAB R18a (programmation) afin de prédire le taux d'adsorption

L'optimisation de l'architecture du RNA consiste à la détermination :

- du nombre des neurones dans les couches cachées.
- de la fonction d'activation des couches cachées et la couche de sortie.
- de l'algorithme d'apprentissage, par comparaison des performances des RN sur la base d'apprentissage, test et validation en termes de la racine d'erreur quadratique moyenne (RMSE) (IV.1).

Avec :

$$\mathbf{RMSE} = \sqrt{\frac{\mathbf{1}}{\boldsymbol{n}} \Sigma_{\boldsymbol{i=1}}^{\boldsymbol{n}} [\boldsymbol{Y_{cal} - Y}]^{\mathbf{2}}} \qquad \text{(IV. 1)}$$

$$\mathbf{R}^2 \equiv 1 - \frac{\Sigma_{\boldsymbol{i}}^{\boldsymbol{n}} [\boldsymbol{Y_{cal} - Y}]^{\mathbf{2}}}{\Sigma_{\boldsymbol{i}}^{\boldsymbol{n}} [\boldsymbol{Y_{cal} - Y}]^{\mathbf{2}}} \qquad \text{(IV. 2)}$$

n : Le nombre des points des quantités adsorbées.

IV.2.1. Concept du réseau de neurones de type feedforward :

Les neurones artificiels sont arrangés en couches, où la couche d'entrée reçoit des signaux d'entrée (x_i) du monde réel et chaque couche successive reçoit les sorties pondérées ($w_{j,\,i}$) de la couche précédente comme son entrée résultant ainsi en un RNA de type feedforward (cas de perceptrons multicouches), dans lequel chaque sortie d'une couche est alimentée en avant à la couche qui la succède où elle est traitée. Les sorties de la dernière couche constituent les sorties au monde réel.

Dans un tel RNA de type feedforward un neurone, dans une couche cachée ou une couche de sortie, à deux tâches :

- Il additionne le biais aux entrées pondérés de plusieurs connexions et applique ensuite une fonction d'activation (dite aussi fonction de transfert ou encore fonction de seuillage) à cette somme comme donnée par l'équation (IV.3)

$$z_j = f\left[\sum_{i=1}^{n} w_{j,i}.\, x_i + b_j\right], j = 1,2, \dots \dots \dots, m \qquad \text{(IV.3)}$$

- Il propage la valeur résultante par les connexions sortantes aux neurones de la couche suivante où elle subit le même processus tel que donné par l'équation (IV.4) (par exemple les sorties de la couche cachée alimentée au neurone k de la couche de sortie donnent la sortie) :

$$v_k = f\left[\sum_{j=1}^{m} w_{k,j}\,.\, z_j + b_k\right], \quad k = 1,2, \dots \dots, l \qquad \text{(IV.4)}$$

En combinant des équations IV.3 et IV.4 on obtient la relation entre la sortie v_k et les entrées du RN :

$$v_k = f\left[\sum_{j=1}^{m} w_{k,j}.\, f\left[\sum_{i=1}^{n} w_{j,i}.\, x_i + b_j\right] + b_k\right] \qquad \text{(IV.5)}$$

Enfin. Il propage la valeur résultante par les connexions sortantes aux neurones de la couche suivante où elle subit le même processus de calcul donné par l'équation III.5 :

$$u_p = f\left[\sum_{k=1}^{l} w_{p,k}.\, v_k + b_p\right], p = 1,2, \dots \dots, h \qquad \text{(IV.6)}$$

En combinant des équations IV.5 et IV.6 on obtient la relation entre la sortie u_p et les entrées du RN :

$$u_p = f\left[\sum_{k=1}^{l} w_{p,k}.\, f\left[\sum_{j=1}^{m} w_{k,j}.\, f\left[\sum_{i=1}^{n} w_{j,i}.\, x_i + b_j\right] + b_k\right] + b_p\right] \qquad \text{(IV.7)}$$

IV.2.2. Nombre de neurones et de couches cachées :

Le nombre de neurones dans la couche d'entrée et la couche de sortie est fixé par le nombre de variables indépendantes et dépendantes respectivement. Il n'y a pas de règles générales qui fixent le nombre de neurone et le nombre de couches cachées dans un MLP pour un problème donné. Par conséquent la stratégie d'essai et d'erreur est la plus raisonnable. Dans cette étude, le nombre de neurone dans chaque couche cachée a été testé pour une et pour deux couche cachée avec différentes fonction de transfert. Le nombre de neurone dans le cas d`une seule couche cachée a été variée de 1 à 20 neurones, et pour le cas des deux couche cachée entre 1 à 20 pour la premier et pour la deuxième couche cachée. Le nombre de neurones dans chaque couche cachée est fixé par le

modélisateur à partir d'un programme MATLAB® par rapport à l'erreur qu'on a fixé, chaque architecture a été répéter 200 fois.

IV.2.3. Concept du réseau de neurone optimal de type feedforward (MLP) :

Les neurones artificiels sont arrangés en couches, où la couche d'entrée reçoit des signaux d'entrée (u_i) du monde réel et chaque couche successive reçoit les sorties pondérées ($w_{i,j}$) de la couche précédente. Les sorties de la dernière couche constituent les sorties au monde réel. Le schéma du RNA de type "MLP" à rétro-propagation est utilisé pour modéliser le taux d`adsorption est représentée sur la Figure II.3.

La méthodologie consiste à faire varie le nombre de neurones dans chaque couche cachée, le tableau (voir annexe le tableau.1 et le tableau .2) représente les erreurs pour chaque nombre de neurone dans les couches cachées. D`après les résultats obtenue on a observé que la structure neuronale avec deux

couches cachées est la plus performante, avec l`erreur de la racine quadratique moyenne minimale correspond aux 11 neurones dans la premier couche cachée et 4 neurones pour la deuxième couche cachée et la fonction de transfert tangent sigmoïde pour les deux couche cachées et la fonction de transfert pureline pour la couche de sortie.

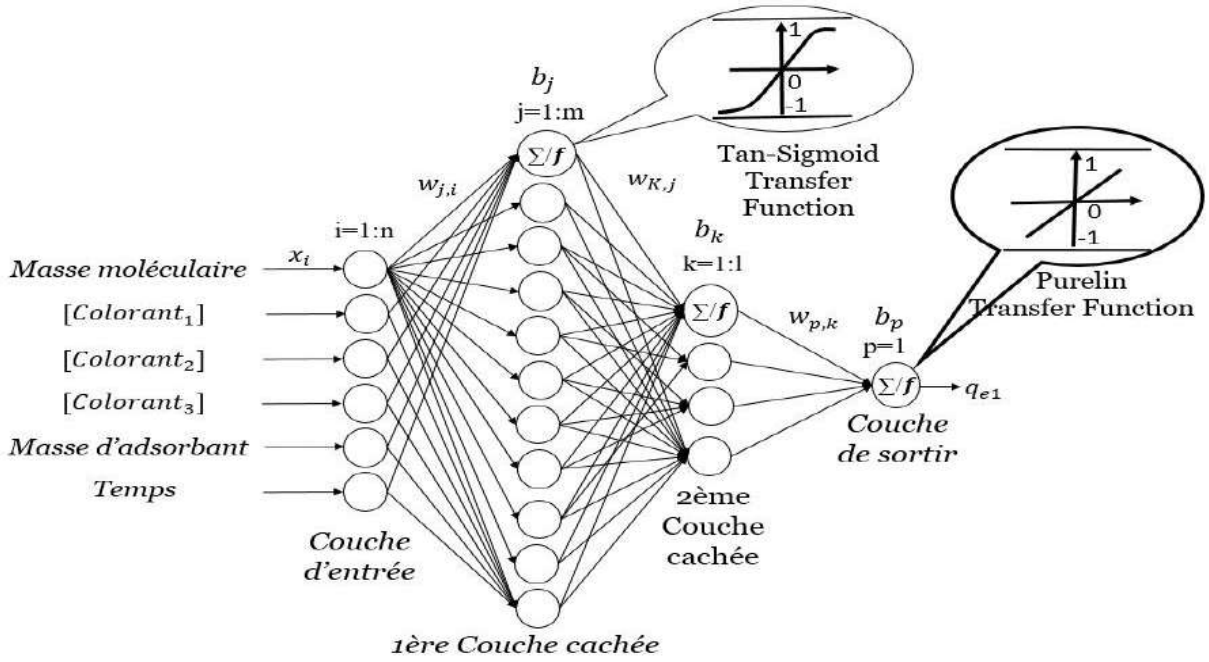


Figure IV.1 : Réseau de neurones artificiels de type feedforward.

La figure IV.2 représente la différence en termes d'erreur pour les nombres de neurones dans chaque couche cachée.

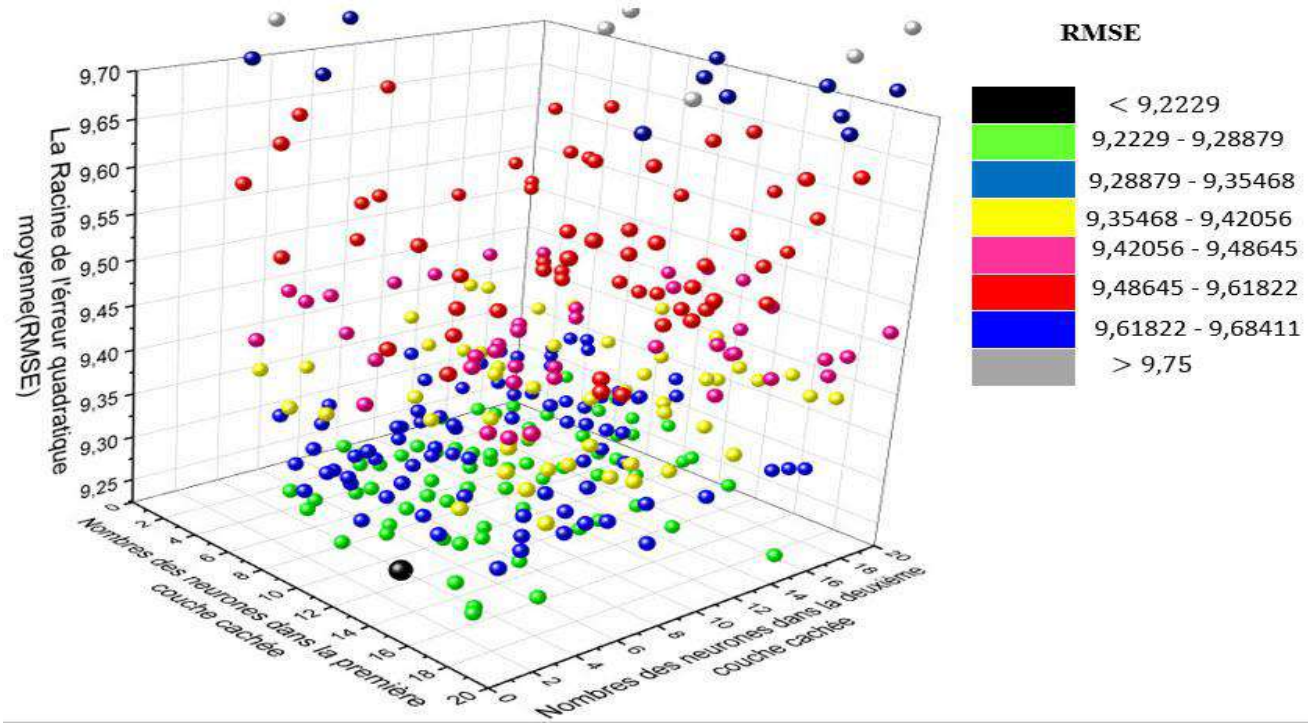


Figure IV.2 : la différence en termes d'erreur pour les nombres de neurones dans chaque couche cachée.

IV.2.4. Interprétation des résultats RNA :

Les résultats de performances du modèle du réseau de neurones établies pour les phases d'apprentissage, test, validation et globale (Apprentissage + Test + Validation) pour la prédiction de la quantité adsorbée sont présentés sur les figures de IV.3 à IV.6 montre bien que la majorité des points sont situés sur la première bissectrice avec un coefficient de détermination approchant l'idéal [α (pente), β (ordonnée à l'origine), R (coefficient de détermination)] = [0.86, 7.6, 0.9260]$_{All}$. Ce qui confirme la robustesse de modèle du RNA.

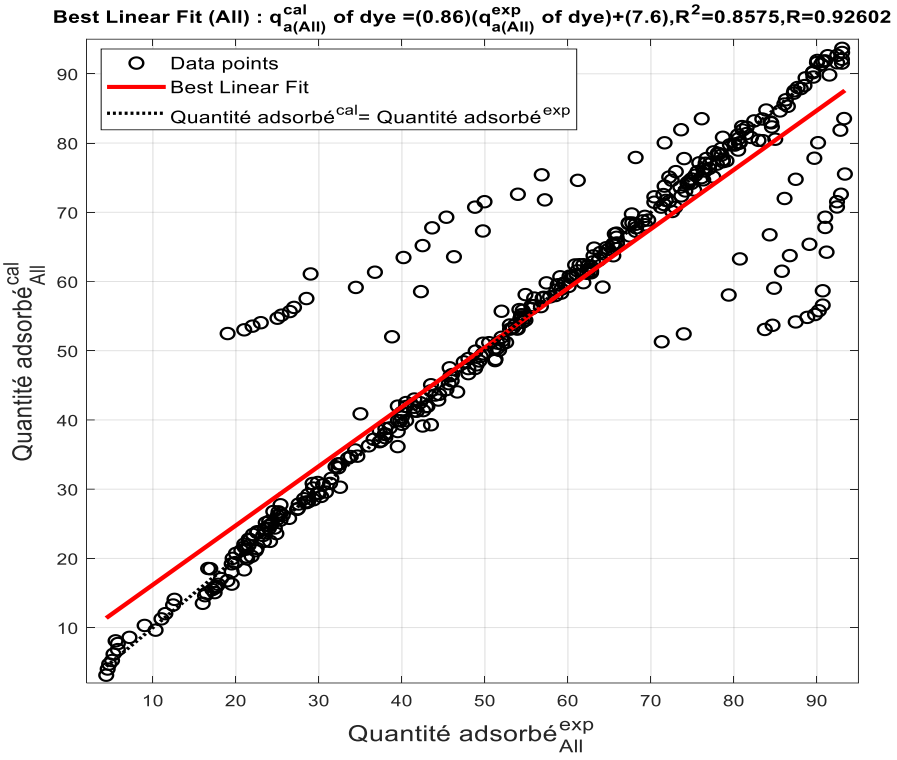


Figure IV.3 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour les phases d'apprentissage, test et validation (Globale).

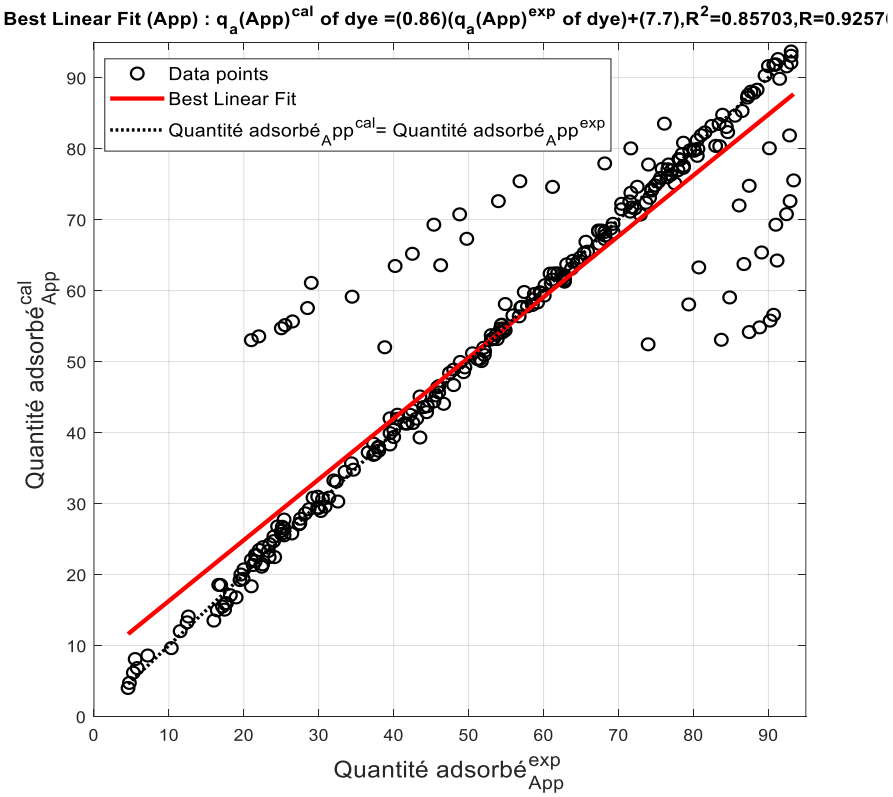


Figure IV.4 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase d'apprentissage.

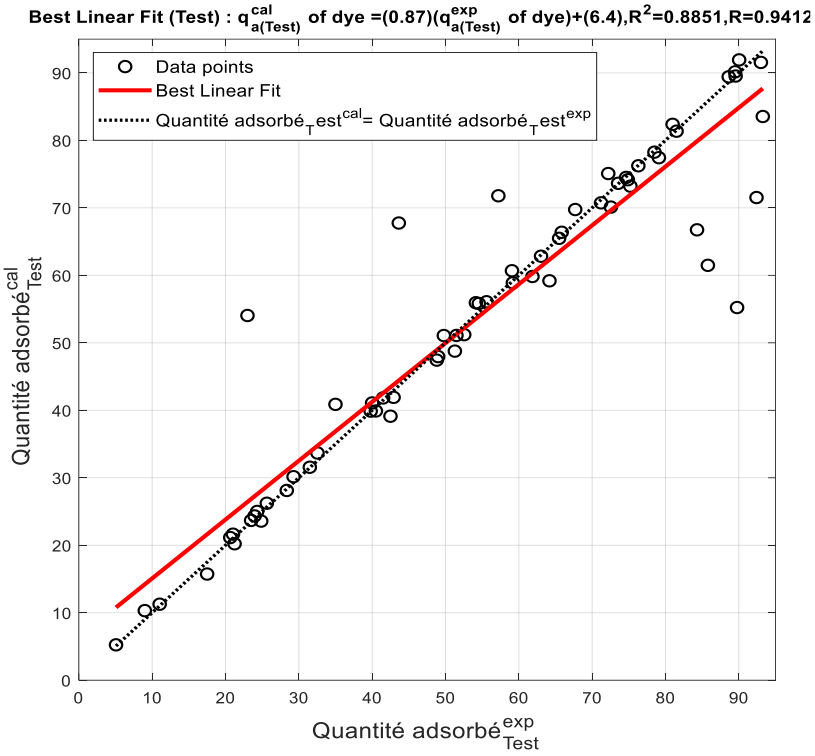


Figure IV.5 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase de test.

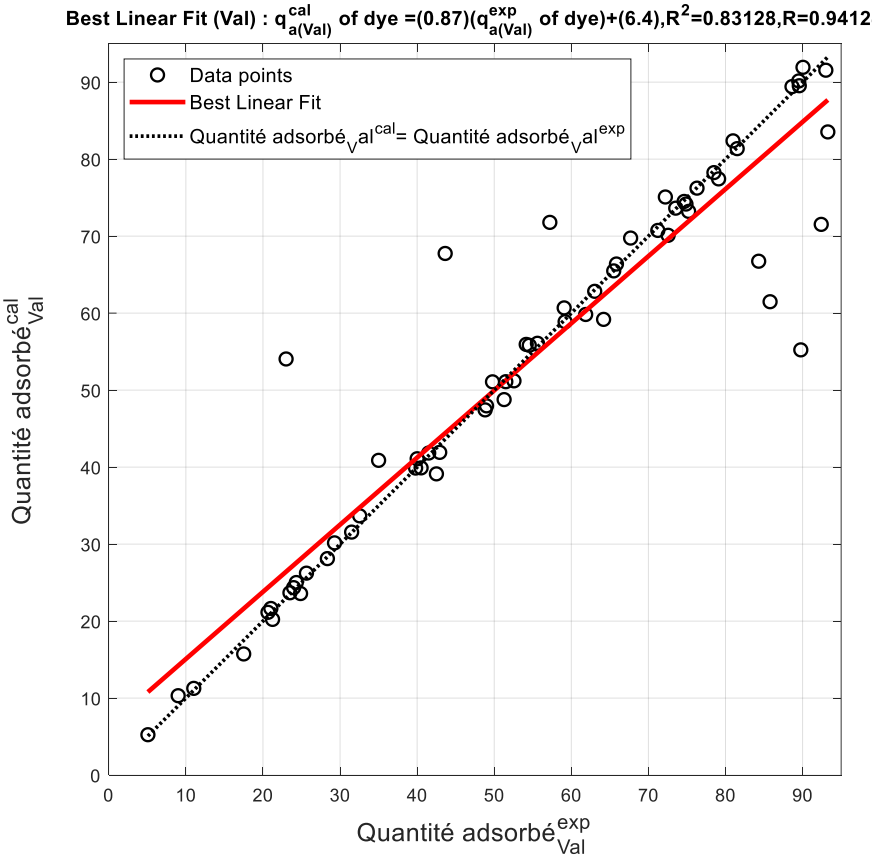


Figure IV.6 : Courbe de régression linéaire de la quantité adsorbée calculée par le RNA optimisé avec la quantité adsorbée expérimentale pour la phase de validation.

Tableau IV.1 : Résultats des paramètres statistiques du modèle RNAO développé dans ce travail.

Type d'erreur	Phase (App)	Phase (Test)	Phase (Val)	Phase (All)
MSE	0.0054	23.8173	0.4696	2.6588
RMSE	0.0736	4.8803	0.6852	1.6306
NRMSE	0.0014	0.0897	0.0129	0.0303
MAE	4.1517	3.7009	4.8686	4.1950
MAPE	9.4169	7.5649	12.3419	9.5912
ERA	9.2730	1.1040	2.6482	13.0252
α	0.86	0.87	0.87	0.86
β	7.7	6.4	6.4	7.6
R	0.9257	0.9412	0.9412	0.9260
$\mathbf{R^2}$	0.8570	0.8851	0.8313	0.8575

IV.3. Résultats et discussion par l'ANFIS :

IV.3.1. Interprétation des résultats ANFIS :

Dans cette partie, l'ANFIS est utilisé pour la modélisation non linéaire pour la prédiction de taux d'adsorption, en utilisant les mêmes données expérimentales de la première interprétation utilisée pour élaborer le modèle du RNA.

La fonction MATLAB est utilisée, pour tracer l'ensemble des données d'apprentissage de test et globale prédites par rapport aux données expérimentales. Les figures de IV.7 à IV.9 représentes les courbes de régression des données calculées par le modèle ANFIS par rapport aux données expérimentales avec un vecteur d'accord, [α (pente), β (interception y), R (coefficient de détermination)] = [1, 0.22, 0.9981] $_{All}$. Ce qui confirme la robustesse du modèle d'ANFIS.

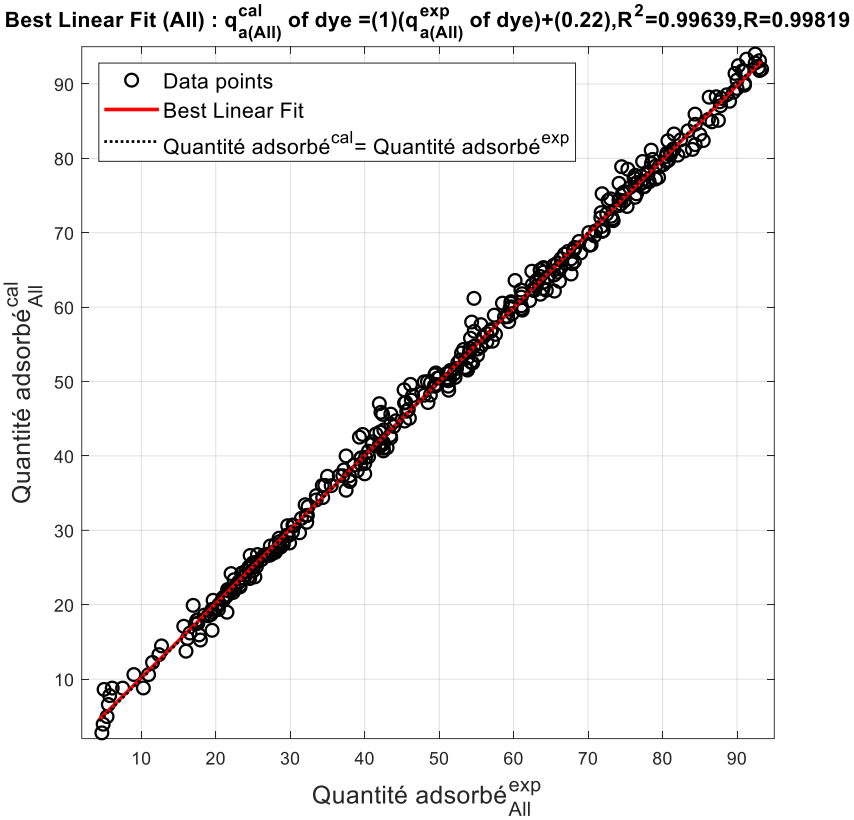


Figure IV.7 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour les phases d'apprentissage, et test (Globale).

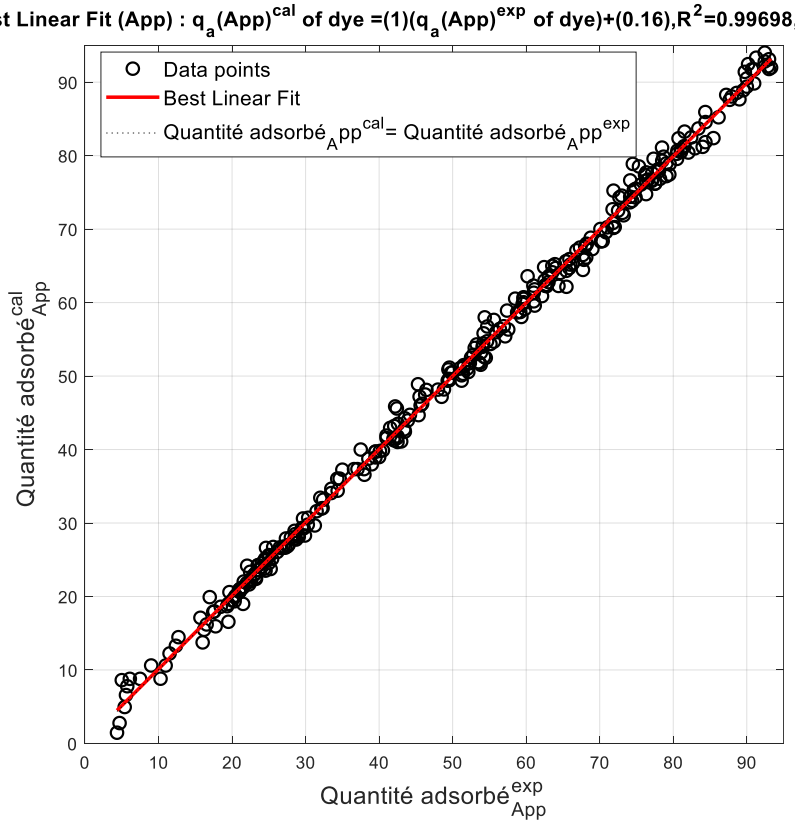


Figure IV.8 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour la phase d'apprentissage.

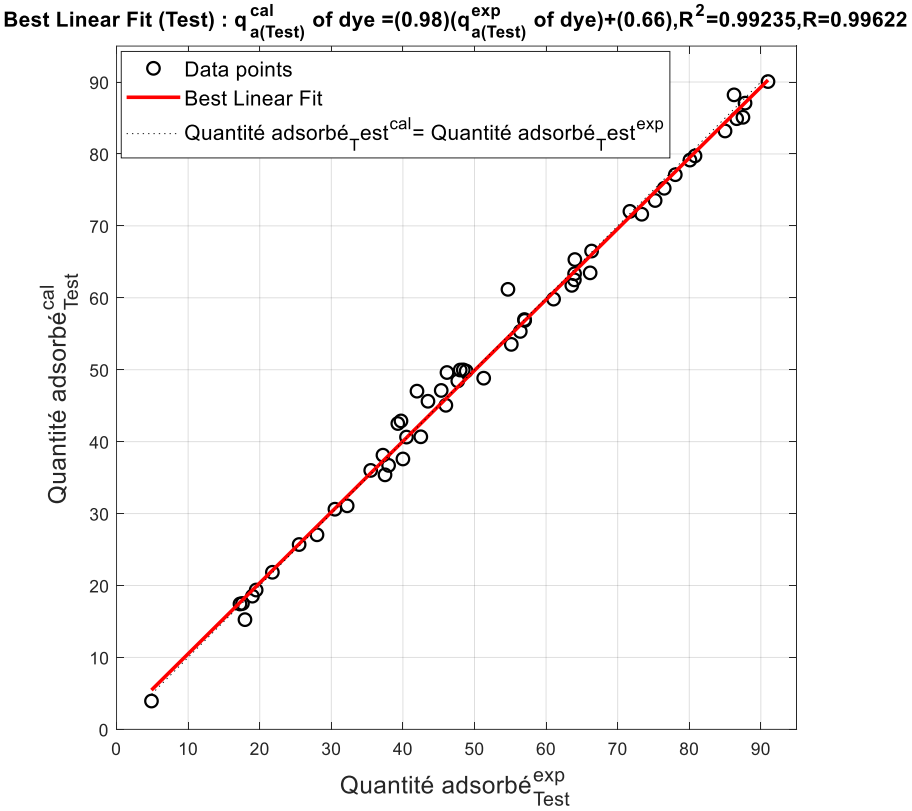


Figure IV.9 : Courbe de régression linéaire de la quantité adsorbée calculée par ANFIS optimisé avec la quantité adsorbée expérimentale pour la phase de test.

Tableau IV.2. Paramètres statistiques du modèle ANFIS développé dans ce travail.

Type d'erreur	Phase (App)	Phase (Test)	Phase (All)
MSE	$4.6801*10^{-10}$	0.8849	0.1316
RMSE	$2.1633*10^{-5}$	0.9407	0.3627
NRMSE	$4.2432*10^{-7}$	0.0182	0.0071
MAE	0.9885	1.4502	1.0571
MAPE	3.1932	3.3807	3.2211
ERA	0.7546	0.2789	0.4757
α	1	0.98	1
β	0.16	0.66	0.22
R	0.9984	0.9962	0.9981
R^2	0.9970	0.9924	0.9964

IV.4. Comparaison entre le RNA et ANFIS:

La Comparaison entre les deux modèles étudiés (RNA et ANFIS) en terme de la racine quarée de l'erreur quadratique moyenne et le coefficient de correlation est présentée dans le tableau IV.3.

Tableau IV.3. Comparaison entre le RNA et ANFIS

Type des méthodes	R^2	RMSE
RNA	0.8575	1.6306
ANFIS	0.9964	0.3627

Les resultants montrent que les deux modèles ont une haute capacité de prediction, néaumoins le modèle de L'ANFIS présente une superiorité de prediction par apport le RNA.

IV.5. Interface graphique:

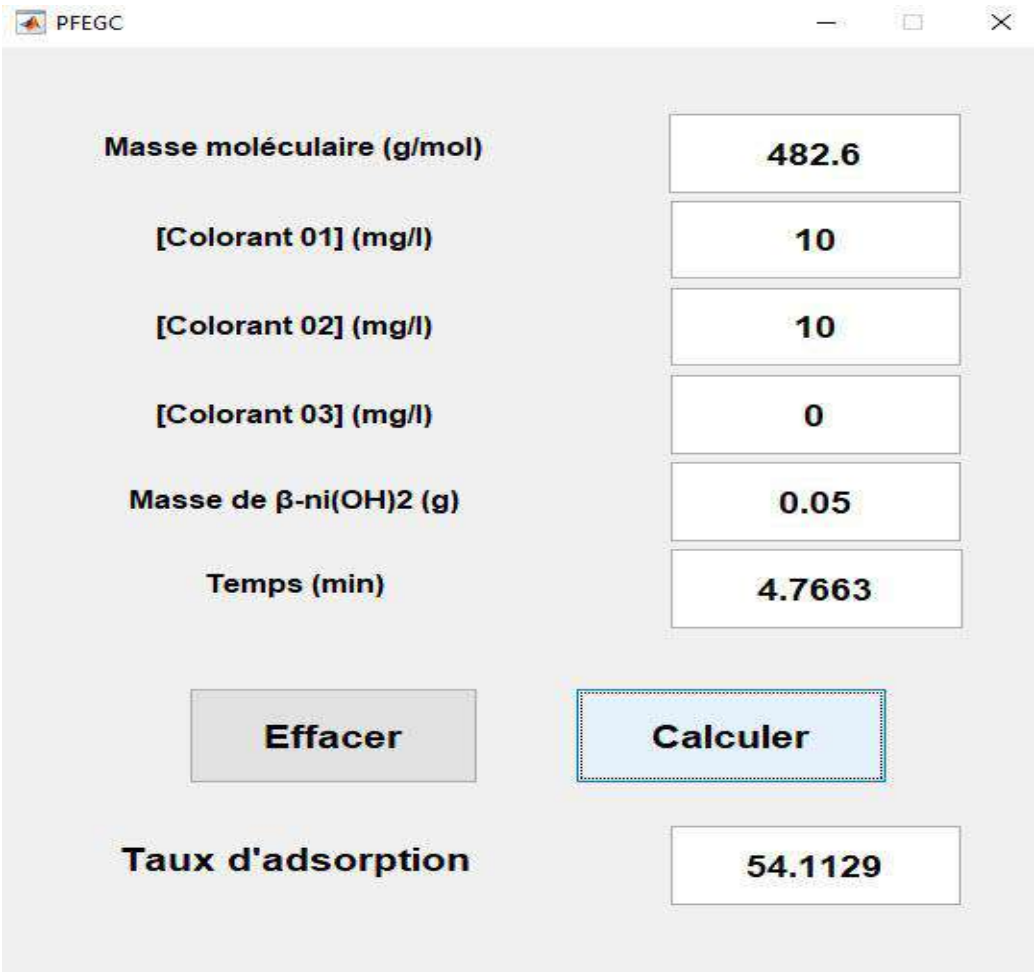


Figure IV.10. Interface graphique du modèle ANFIS

Afin de simplifier la complexité du modèle mathématique élaboré par la meilleure modélisation obtenue dans le présent travail, une interface graphique (également appelée interface d'utilisateur) est développée pour améliorer la convivialité du modèle ANFIS développé. Cette interface graphique d'utilisateur est un outil qui permet l'utilisation directe et sans effort du modèle de ANFIS pour calculer la quantité adsorbée. A cette fin, cette interface a été créée pour le calcul de la quantité adsorbée dans l'intervalle des variables d'entrées. Pour cela un programme MATLAB a été conçu avec une capture d'écran de l'interface résultante.

IV.5. Conclusion:

L'objectif principal de la présente travail était d'étudier les capacités d'utilisation des modèles de réseau neuronal artificiel (RNA) et de système d'inférence floue basé sur un réseau adaptatif (ANFIS) pour prédire le pourcentage d'élimination des colorants.

Par ailleurs de collecter une base de données sur la variation de la quantité adsorbée des colorants à partir des résultats expérimentaux mesurés afin d'élaborer des modèles d'intelligence artificiels corrélatif /prédictifs de la quantité adsorbée des colorants en fonction des conditions opératoires.

Après une étude de comparaison entre les deux modèles prédictifs proposés dans cette étude, le modèle ANFIS surpasse significativement le modèle du RNA proposé en terme d'erreur et de temps d`apprentissage. Les résultats obtenus confirment la robustesse du modèle ANFIS établi.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Conclusion générale

L'objectif de cette étude est de modéliser le phénomène de l'adsorption d'un système mono et bi-composant des colorants sur l'hydroxyde de nickel β-ni$(OH)_2$ par les méthodes d'intelligences artificielles (RNA et ANFIS) .

L'avantage principal de ces modèles est la capacité de résoudre les relations complexes non linéaires de différents systèmes.

Pour le réseau de neurone artificielle, Le modèle optimale a une structure de (6-11-4-1) : {6 neurones dans la couche d'entrée ; 11 neurones dans la première couche cachée ; 4 neurones dans la deuxième couche cachée et 1 seul neurone dans la couche de sortie} avec l'utilisation de la fonction d'activation tangent sigmoïde et purlin respectivement dans la couche cachée et dans la couche de sortie. L'algorithme d'apprentissage de Levenberg-Marquardt a été adapté.

Les résultats statistiques de RNA présente un erreur : (RMSE= 1.6306) et le coefficient de corrélation (R= 0.926) pour la totalité de la base des données et (R=0.94) pour la phase de validation.

Les résultats numériques ont fait l'objet aussi d'une modélisation par (ANFIS) de la quantité adsorbée mesurées en fonction des conditions physico-chimique. Les résultats montrent un RMSE= 0.3627 et un coefficient de corrélation R= 0.9981.

Par conséquent, les résultats obtenus prouvent la robustesse des modèles utilisés. Par ailleurs en termes de comparaison, le modèle de L'ANFIS a donné des résultats plus significatifs.

Les perspectives envisagées dans le futur sont :

- Utilisation d'autres systèmes adsorbant/adsorbat.
- Utilisation d'autres modèles prédictifs intelligents.

REFERENCES BIBLIOGRAPHIQUES

[1] : Ibrir, A.“Modélisation neuronale et empirique de l’adsorption d’un système multi composants’’, Mémoire de Master, université de Médéa, Algérie,(2017)

[2] : Xu, Z., Cai, J. G., Pan, B. C. “Mathematically modeling fixed-bed adsorption inaqueous systems ’’, J Zhejiang Univ-Sci A (Appl. Phys&Eng), 14(3), 155-176 ,(2013)

[3]: Sediri, M. “Contribution a la modélisation de l’adsorption dynamique : Etude comparative’’, Thèse de doctorat, université de Médéa, Algérie, (2017).

[4]:Sido-Pabyam, M., Guèye.M, Blin,J., Somé, E.“Valorisation de résidus de biomasse en charbons actifs-Tests d’efficacité sur des bactéries et dérivés de pesticides’’, Sud sciences et technologies semestriel N°17, Institut International de l’Ingénierie de l’Eau et del’environnement , (2009).

[5]:Losi, M. E., Amrhein, C., Frankenberger, W. T. “Biodegradation andbioremediation. Bioremediation of chroamte- contaminated groundwater by reduction and precipitation in surface soils’’,J. Enviro. Gual, 23, 141 – 1150, (1994).

[6]: Hemsas, S. “Contribution à l’étude de la décoloration des eaux sur grignons d’olives valorisés. Etude dynamique’’, Mimoire de magister, Université de Boumerdès, Algérie,(2008).

[7]: Boucif,A. “Etude de la Co-adsorption de deux pesticides (Durion et Metribuzine) sur un charbon actif en poudre’’, mémoire d’ingénieur d’état en chimie industrielle, école nationale supérieure polytechnique, 2008.

[8] : Amimeur,D.“Contribution à l’étude de l’élimination du plomb par coagulation floculation et par adsorption sur charbon actif. Effet de la minéralisation et des paramètres réactionnels’’, Thèse de doctorat,Université Mohamed Khider – Biskra, Algérie,(2018).

[9] : Chaouch,N.“Utilisation des sous-produits du palmier dattier dans le traitement physico-chimique des eaux polluées’’, Thèse de doctorat,Université hadj Lakhdar – Batna,(2014).

[10] :Leclerc, V. “Etude de la co-adsorption de molécules organiques et de cations minéraux sur charbons actifs’’, Thèse de doctorat, Université de Limoges, n°d'ordre 28,(1995).

[11] :Chittour, C. Physico chimique des surfaces,2eme édition, Tome2,461 p,(2004).

[12] : Bouziane, T. “Etude de la capacité adsorbante de charbon actif commercial application au traitement des eaux’’. Mémoire ingéniorat, université Kasdi Merbah , Ouargla, Algérie, 47 , (2001).

[13] :koller, E. Aide-mémoire Génie chimique, 2éme Edition DUNOD,364- 366 Avril, (2005).

[14] : Bahloul, N.“Etude de l’adsorption du colorant anionique Rouge 2sur charbons actif et argiles modifiées’’, université des sciences et de la technologie d’Oran «Mohamed Boudiaf», Algerie, 2014.

[15] : Cauderc, G.“Contribution à l’étude d’adsorption binaire par les carbones non poraux et poreux ’’, Thèse de doctorat, Université de Neuchâtel, Suisse,(2002).

[16] Mancuso, T. F.“Consideration of chromium as an industrial carcinogen’’, Int.
Conf. Heavy Metals Environment. Toronto. Ont,27-31, 343-356,(1991).

[17] : De Flora, S., Wetterhahn, K. E. “Mechanisms of chromium metabolism and genotoxicity”, Life. Chemi. Reports. 7, 169- 244, (1989).

[18]: RJ.Newcornbe,Wrickott, R.M., Wilson, J.M., Ardenaro, A. “Manipulation de chimie physique’’, traduction français par S.Courbet,(1964).

[19]: Masschelein,W. J. “Processus unitaires du traitement de l'eau potable’’, Ed, Cebedoc Sprl, Liége, (1996).

[20] : Brevet APG-RCC : PCT / FR 99 / 00748 du 31 mars,(1999).

[21] :La franque,Pollet, JP.,Garforth,N., Phytoma,B.Phys.Chem, 9, 5-49,(1993).

[22] : Rebouh, S. “Utilisation des différents techniques d’intelligence artificielle pour la modélisation du procédé de séparation par adsorption solide-liquide : étudecomparative ’’, Thèse de doctorat, Université de Médéa, Algérie, (2015).

[23] : Ediline, F. “L’épuration physicochimique, théorie et technologie des eaux’’, Ed. CEBEDOC Sprl, liége,(1998).

[24] : Moreau,S.“ L’adsorption et l’environnement’’, ENS (2003).

[25] : Charrière, D. “Caractérisation de la sorption de gaz sur les charbonsApplication au stockage géologique du dioxyde de carbone dans les veines de charbon’’,Thèse de doctorat, université de,Toulouse, France,(2009).

[26] : AFNOR. La qualité des sols, thermologie, échantillonnage, contrôle et qualité,
Tomme 1, Editor AFNOR, Paris, p 299-310,(1996).

[27] : Sekirifa,M.L.“Etude comparative de la capacité adsorbante de charbons activés issus de noyaux de quelques variétés de dattes ’’, Application dans le traitement des eaux. Thèse deMagistère, Université. Annaba, p69, (2000) .

[28] : Dali,S. : “Caractérisation d’une argile (Kaolin) de la région de Annaba pour l’adsorption du phénol’’. Mémoire d’ingéniorat, Université Kasdi Merbah,Ouargla, Algérie,32 – 69, (2005).

[29] : Hannachi, A., Habaili, D., Chtara,C., Ratel,A. "Purificationof wet process phosphoric acid by solvent extraction with TBP and MIBK mixtures'',Sep.Purif.Technol,55(2), 212-216,(2007).

[30] : Calvet, R. Le sol, "Propriété et fonctions, tome1 constitution et structure, phénomènes aux interfaces'', Editions France Agricole, P318,(2003).

[31] : Zarrouki, M. "Etude de l'adsorption dans un système liquide-solide :solutuion d'ion dicyanoaurate - charbon actif '', Thèse de doctorat, Ecole Nationale Superieure Des Mines De Saint Etienne, France,(2013).

[32] : Krou, N. J. "Etude expérimentale et modélisation d'un procédé séquentiel, AD-OX d'élimination de polluants organiques''. Thèse de doctorat, Institut National Polytechnique de Toulouse, France,(2010).

[33] Halsey, G.D."The role of surface heterogeneity'', Advances Catalysis,4, 259-269, (1952).

[34] Fiani, "Adsorption de polluants gazeux sur des filtres à charbon actif, Modélisation des échanges couplés de matière et de chaleur'', INPG-EMSE, Saint-Etienne, France. (2000).

[35] Belle, J.P., Jersale ,C."Elimination des fluorures par adsorption sur alumina active'', TC. A.S.M, p 87-93,(1984).

[36] Industrial alumina chemicals, ACS Monograph, 184 (1986).

[37] BARKA, N. (2008). L'élimination des colorants de synthèse paradsorption sur un phosphate nature et par dégradation photo catalytique sur TiO2 supporté''.Thèse de Doctorat Université IBN ZOHR , AGADIR, Maroc

[38]:Otabbong, E. "Chemistry of Cr in sommeswedish soils: transformation andchanges in pH and cation exchange capacity in two soils incubated with potassiumchromate''. Commun. In Soil. Sci. Plant Anal. 21(9, 10), 687- 703, (1990).

[39]: Langmuir, I."The constitution and fundamental propreties of solids andliquids'', Am. J. Chem. Soc. 38, 2221-2295, (1916).

[40]: Seo,D.C."Phosphorus retention capacity of filter media for estimating the longevity of constructed Wetland'', Water Research 39 , 2445 – 2457 (2005).

[41]: Li,J.M. "Adsorption of phenol, p – chlorophenol and p – nitrophenol onto functional chitosan''. Bioresource Technology ,100 ,1168 – 1173, (2009).

[42] : Mardini,F.Al. "Etude de l'adsorption du pesticide bromacil sur charbon actif en poudre en milieu aqueux. Effet compétiteur des matières organiques naturelles''. Mémoire de Master, Chimie et microbiologie, Université de Poittiers,Fance. (2008).

[43]: Valix, M.“Preparation of activated carbon using low temperature carbonisation and physical activation of high as raw bagasse for acid dye adsorption’’,Chemosphere, 56 ,493 – 501, (2004).

[44]: M.A. Ahmad Zaini . “Adsorption of aqueous metal ions on cattle – manure – compost based activated carbons’’,Journal of Hazardous Materials ,170 ,1119 – 1124,(2009).

[45]: B.H.Hameed, J.M. Salman, A.L. Ahmad “Adsorption isotherm and kinetic modeling of 2,4 – pesticide on activated carbon derived from date stones”, Journal of Hazardous Materials, 163 ,121 – 126,(2003).

[46] : M.L,Sekirifa, M Hadj-Mahammed“Etude comparative de la capacité absorbante d’un charbon actif issu de noyaux de dates et un charbon actif commercial’’,Sciences et Technologie, B 23 55 – 59, (2005).

[47]: A .Ucer, A. Uyanik, S.F. Aygun: “Adsorption of Cu (II), Cd (II), Zn (II), Mn (II) and Fe (III) ions by tannic acid immobilized activated carbon’’, Separation and Purification Technology, 47,113-118,(2006).

[48]: K. Kadirvelu, C. Faur-Brasquet, P.L. Cloirec: “Removal of Cu (II), Pb (II) and Ni (II) by adsorption onto activated carbon cloth”,Langmuir, 16 ,8404 – 8409(2000).

[49] : Zemouri. K., Zougagh. D.“Etude de l’adsorption de colorants organiques (Bleu de Méthylène et Méthyle Orange) sur les coquilles de noix de coco’’ , Mémoire de master , université Abderrahmane MIRA de Bejaia.(2019).

[50] : Gherbi, N. “Etude expérimentale et identification du processus de rétention des cationsmétalliques par des matériaux naturels’’,Thèsede Doctorat, universitéde Menttouri de Constantine, Algérie,(2008).

[51] :Halsey, G. “Physical Adsorption on non-uniform surfaces’’. J. Chem. Phys. 16, 931-937, (1948).

[52]: Harkins, W. D., Jura, E. J. “The decrease of free surface energy as a basis for the development of equations for adsorption isotherms; and The Existance of Two Condensed Phases in Films on Solids ’’,J. Chem. Phys, 12, 112-113,(1944).

[53] : Oliveira, T.F. “Etude d’un procédé de dépollution basé sur le couplage ozone/charbon actif pour l’élimination des phosphates en phase aqueuse’’. Thèse de Doctorat, université d’Orleans. France,(2011).

[54] :Abouarnadasse, S. “L’élimination du bleu de méthylène par une argile naturelle de Tazaen milieu aqueux’’,Int. J. Innov. Res. Adv. Eng, (2014).

[55]: Ho, Y.S.“kinetic rate equation on adsorption reactions’’,Scientometrics,(2004).

[56]: Weber, Jr. W. J., Morris, J.C., Sanit, J. “Kinetics of adsorption on carbon fromsolution’’,Eng. Div. Proceed. Am. Soc,Civil Eng. 89 , 31-59,(1963).

[57]: Crank, J. “The mathematics of diffusion’’,Clarendon Press Oxford, Second Edition,(1975).

[58] : Lecerf, G. “Développement d’un réseau de neurones impulsionnels sur silicium à synapses memristives’’. Thèse de doctorat, Université de Bordeaux, France,(2014).

[59] : Ibrir, A. “Contribution à l'étude en trois dimensions (3d) de la dispersion d'un polluant gazeux dans un milieu urbain’’,Thèse de doctorat, Université de Médéa, Algérie,(2022).

[60] : Krenker, A., Janez, B., Andrej, K. 2011. “Introduction to the Artificial Neural Networks.” InTech, 1–18,(2011).

[61] :Oussar, Y. “Réseaux d’ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus’’, Thèse de doctorat, Université Pierre et Marie Curie. Paris VI, France,(2004).

[62] :Ammar, MY.“Mise en oeuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles envue de la transposition Batch/Continu’’,Thèse de Doctorat de l’I.N.P. Toulouse, Fance,(2007).

[63] : Haykin, S. “Neural networks - A comprehensive foundation macmillan collège publishing company’’, New York,(1944).

[64] : Bishop, CM. “Neural networks for pattern recognition’’, Oxford university press,(1995).

[65] : Mcculloch, W.S., Pitts ,W.“A logical calculs of the ideas immanent in nervous activity, Bulletin of Math’’, Biophysics, 5, pp. 115-133, (1943).

[66] : Minsky, M., Papert, S.“Perceptrons : an introduction to computational geometry’’, MIT Press, expanded edition, (1988).

[67] :Laidi, M.“Etude et modélisation d’un réfrigérateur solaire’’. Thèse de doctorat, université de Médéa, Algérie,(2013).

[68] : Lippmann, R. “An Introduction to computing with neural nets’’, IEEE ASSP Magazine. 4, 4-22, (1987).

[69] :Poggio T,. Girosi, F. “Network for approximation and learning procceedings of the IEEE.vol. 78,n°9.p. 1481-1497,(1990).

[70] : Cherif, A. “Réseaux de neurones, SVM et approches locales pour la prévision des séries temporelles. Thèse de doctorat, Université Fançois Rabelais de Tours, France,(2013).

[71] : Le Cun Y. “Une procédure d’apprentissage pour réseau à seuilassymétrique’’, Cognitiva 85, Paris, France, (1985).

[72] : Si-Moussa, C.“Modélisation des équilibres de phases à pression élevées par les réseaux de neurones artificiels’’, Thèse de doctorat en génie chimique, Ecole Nationale polytechnique, El-Harrach, Alger,(2010).

[73] :Hebb D.O.The organisation of behavior, Wiley, New-york, (1949).

[74] : Liao, S. H., Wen, C. H.“Artificial neural networks classification and clustering of methodologies and applications-literature analysis from1995 to 2005’’, Expert systems with applications, 32(1), 1-11,(2007).

[75] : Laidi, M., Hanini, S. “Optimal solar COP prediction of a solar-assisted adsorption refrigeration system working with activated carbon/methanol as working pairs using direct and inverse artificial neural network’’. Int. J. Refrig, 36, 247-257, (2013).

[76] : Glorennec, P.-Y. “Quelques aspects analytiques des systèmes d’inférence floue’’. J. Eur. des systèmes Autom. 30, 231–254,(1996).

[77] : Glorennec, P.Y.“Algorithmes d’apprentissage pour systèmes d’inférence floue’’. Hermes. Hagan, M.T., Demuth, H.B., Beale, M.H., 1995. Neural Network Design. Bost. Massachusetts PWS 2, 734,(1999).

[78] :Benimam, H. “Contribution à La Modélisation Du Coefficient d’activité à Dilution Infinie Des Solutés Organiques et de l’eau Dans Les Liquides Ioniques.” Université Yahia Fares de Médéa, Algérie.(2019).

[79] : Mahmoodi ,N ,M ; Hosseinabadi-Farahani ,Z ; Chamani ,H. “Synthesis of nanostructured adsorbent and dye adsorption modeling by an intelligent model for multicomponent systems.” *Korean J. Chem. Eng,2015.*

ANNEXES

Tableau. 1 : L'ensemble des erreurs de chaque nombre de neurone pour une seule couche cachée.

i	Erreur
1	3,371399
2	2,246315
3	1,874646
4	1,745953
5	1,735433
6	1,676152
7	1,684232
8	1,710947
9	1,657465
10	1,646415
11	1,643197
12	1,664413
13	**1,639237**
14	1,670884
15	1,639749
16	1,663882
17	1,705413
18	1,657553
19	1,653787
20	1,694115

Tableau 2. : L'ensemble des erreurs de chaque nombre de neurone pour deux couches cachées.

i	j	Erreur
1	1	2,9688
1	2	2,8524
1	3	2,7496
1	4	2,8053
1	5	2,6058
1	6	2,5377
1	7	2,2756
1	8	2,8761
1	9	2,2048
1	10	2,7342
1	11	2,1113
1	12	1,9697
1	13	3,3068
1	14	2.3607
1	15	2,6510
1	16	1,9015
1	17	1,9201
1	18	3,9565
1	19	3.8963
1	20	2,4408
2	1	2,9889
2	2	1,9808
2	3	2,8737
2	4	2,2008
2	5	1,8252
2	6	1,940
2	7	1,7891
2	8	1,7225
2	9	1,6862
2	10	1,7084
2	11	1,8032
2	12	1,6523
2	13	1,6684
2	14	1,6843
2	15	1,6644
2	16	1,6630
2	17	1,6888
2	18	1,6842
2	19	1,6990
2	20	1,6441
3	1	1,8253
3	2	1,7681
3	3	1,8080
3	4	2,0144
3	5	1,7070
3	10	1,6705
3	11	1,6619
3	12	1,6556
3	13	1,9189
3	14	1,6443
3	15	1,6722
3	16	1,6443
3	17	1,6722
3	18	1,6434
3	19	1,6847
3	20	1,6580
4	1	1,6442
4	2	1,6407
4	3	1,7487
4	4	1,7198
4	5	1,7262
4	6	1,6753
4	7	1,6593
4	8	1.6726
4	9	1,6407
4	10	1,6381
4	11	2,0332
4	12	1,6353
4	13	1,6549
4	14	1,6411
4	15	1,6528
4	16	1,6506
4	17	1,6722
4	18	1,6506
4	19	1,6518
4	20	1,6506
5	1	1,6991
5	2	1,6632
5	3	1,6530
5	4	1,6746
5	5	1,6492
5	6	1,6665
5	7	1,6384
5	8	1,6372
5	9	1,6442
5	10	1,6441
5	11	1,6443
5	12	1,7276
5	13	1,6535
5	14	1,6417
5	15	1,6422
5	20	1,6393
6	1	1,6713
6	2	1,6860
6	3	1,6448
6	4	1,6363
6	5	4,921688
6	6	1,635329
6	7	1,736335
6	8	1,644364
6	9	1,641729
6	10	1,639272
6	11	1,639042
6	12	1,658296
6	13	1,654229
6	14	1,647334
6	15	1,639042
6	16	1,696148
6	17	1,64272
6	18	1,653115
6	19	1,638512
6	20	1,640121
7	1	1,708418
7	2	1,642242
7	3	1,649491
7	4	1,644028
7	5	1,645778
7	6	1,644081
7	7	1,649491
7	8	1,651719
7	9	1,64302
7	10	1,64592
7	11	1,639608
7	12	1,636832
7	13	1,644912
7	14	1,638989
7	15	1,658278
7	16	1,696095
7	17	1,705625
7	18	1,644099
7	19	1,644275
7	20	1,637274
8	1	1,661284
8	2	1,640227
8	3	1,860519
8	4	1,642949
8	5	1,640792

3	6	1,71397	5	16	1,644046	8	6	1,632041
3	7	1,647953	5	17	1,638211	8	7	1,643197
3	8	1,680908	5	18	1,661337	8	8	1,63883
3	9	1,688882	5	19	1,728574	8	9	1,64325
8	10	1,782975	10	20	1,632218	13	10	1,729352
8	11	1,640934	11	1	3,002895	13	11	1,660011
8	12	1,64744	11	2	1,643144	13	12	1,652673
8	13	1,67861	11	3	1,634003	13	13	1,679176
8	14	1,632218	**11**	**4**	**1,630591**	13	14	1,677956
8	15	1,667489	11	5	1,659233	13	15	1,655007
8	16	1,645442	11	6	1,634322	13	16	1,876308
8	17	1,658525	11	7	1,649456	13	17	1,641305
8	18	1,645036	11	8	1,665032	13	18	1,65674
8	19	1,636213	11	9	1,641005	13	19	1,666216
8	20	1,662892	11	10	1,660346	13	20	1,69332
9	1	1,646786	11	11	1,680714	14	1	1,632359
9	2	1,649102	11	12	1,6418	14	2	1,636125
9	3	1,647033	11	13	1,649685	14	3	1,681386
9	4	1,668886	11	14	1,643356	14	4	1,641252
9	5	1,633172	11	15	1,654494	14	5	1,676665
9	6	1,659639	11	16	1,656987	14	6	1,658861
9	7	1,646768	11	17	1,692436	14	7	1,633826
9	8	1,651913	11	18	1,65034	14	8	1,695848
9	9	1,642083	11	19	1,676135	14	9	1,707694
9	10	1,666075	11	20	1,661018	14	10	1,636585
9	11	1,639519	12	1	1,667949	14	11	1,637044
9	12	1,639431	12	2	2,832318	14	12	1,704847
9	13	1,67808	12	3	1,694805	14	13	1,637575
9	14	1,667754	12	4	1,643285	14	14	1,655573
9	15	1,641906	12	5	1,687733	14	15	1,707499
9	16	1,637044	12	6	1,671874	14	16	1,675534
9	17	1,639732	12	7	1,634976	14	17	1,688299
9	18	1,646874	12	8	1,668002	14	18	1,660718
9	19	1,672758	12	9	1,68547	14	19	1,781331
9	20	1,638671	12	10	1,665845	14	20	1,682411
10	1	1,663105	12	11	1,745617	15	1	1,636478
10	2	1,637097	12	12	1,644753	15	2	1,647369
10	3	1,65384	12	13	1,679759	15	3	1,677072
10	4	1,643621	12	14	1,648395	15	4	1,686265
10	5	1,64005	12	15	1,638335	15	5	1,672351
10	6	1,641464	12	16	1,676135	15	6	1,645884
10	7	1,63913	12	17	1,719751	15	7	1,649084
10	8	1,640598	12	18	1,764853	15	8	1,865558
10	9	1,631174	12	19	1,744167	15	9	1,734549
10	10	1,671485	12	20	1,674208	15	10	1,695777
10	11	1,632713	13	1	1,679441	15	11	1,650428
10	12	1,653151	13	2	1,653716	15	12	1,672139
10	13	1,648607	13	3	1,631086	15	13	1,721183

10	14	1,732693		13	4	1,6839493		15	14	1,63365
10	15	1,6350818		13	5	1,6475815		15	15	1,662751
10	16	1,6373978		13	6	1,6614603		15	16	1,709568
10	17	1,6497738		13	7	1,6771602		15	17	1,638688
10	18	1,6571818		13	8	1,6557143		15	18	1,659533
10	19	1,6515065		13	9	1,6661632		15	19	1,743283
15	20	1,6586669		17	13	1,6743314		19	6	1,651666
16	1	1,6792994		17	14	1,671697		19	7	1,700675
16	2	1,6399791		17	15	1,6874676		19	8	1,724048
16	3	1,6666936		17	16	1,8728424		19	9	1,691322
16	4	1,6627863		17	17	1,6450886		19	10	1,748764
16	5	1,6449472		17	18	1,6443107		19	11	1,650234
16	6	1,6564746		17	19	1,6431262		19	12	1,74468
16	7	1,6562094		17	20	1,7390225		19	13	1,684851
16	8	1,658773		18	1	1,639325		19	14	1,743672
16	9	1,6933904		18	2	1,6639002		19	15	1,755164
16	10	1,7554472		18	3	1,8300214		19	16	1,727053
16	11	1,7502316		18	4	1,6381404		19	17	1,667206
16	12	1,6807315		18	5	1,6489959		19	18	1,670017
16	13	1,6881394		18	6	1,649597		19	19	1,730554
16	14	1,655785		18	7	1,657111		19	20	1,735982
16	15	1,6691688		18	8	1,6584194		20	1	1,675021
16	16	1,7656839		18	9	1,6496147		20	2	1,658066
16	17	1,6766651		18	10	1,6547419		20	3	1,705448
16	18	1,8447666		18	11	1,6841968		20	4	1,679052
16	19	1,6922235		18	12	1,6670649		20	5	1,677478
16	20	1,6556966		18	13	1,8892141		20	6	1,660806
17	1	1,6568458		18	14	1,7806058		20	7	1,648006
17	2	1,6370973		18	15	1,667224		20	8	1,687609
17	3	1,6674008		18	16	1,7209182		20	9	1,690296
17	4	1,645177		18	17	1,7149246		20	10	1,779174
17	5	1,7855386		18	18	1,6680726		20	11	1,659993
17	6	1,6501274		18	19	1,6592503		20	12	1,759991
17	7	1,6534866		18	20	1,7178949		20	13	1,708436
17	8	1,716339		19	1	1,6494379		20	14	1,636514
17	9	1,7495421		19	2	1,6624327		20	15	1,71496
17	10	1,6808906		19	3	1,7012757		20	16	1,70665
17	11	1,7928934		19	4	1,7548991		20	17	1,780199
17	12	1,720264		19	5	1,6788044		20	18	1,741409
								20	19	1,675215
								20	20	1,766674