République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITE DE MEDEA

Faculté de Technologie

Département de Génie des Procédés et Environnement

MEMOIRE DE FIN D'ETUDES

En vue de l'obtention du diplôme de Master en Génie des Procédés

Spécialité : Génie Chimique

Thème

Modélisation de la viscosité des liquides par intelligence computationnel

Réalisé par :

M^elle^ TERBICHE Zohra

M^elle^ MEKKID Manel

Proposé et dirigé par :

Dr. KHAOUANE Latifa

Co-dirigé :

Pr. HANINI Salah

Dr. ROUBEHIE FISSA Mohamed

2020/2021

Remerciement

Nous tenons à remercier ALLAH Le Tout Puissant pour nous avoir préservé, donné la santé, et guidé vers la connaissance et le savoir. Et « quiconque ne remercie pas les gens, ne remercie pas ALLAH».

Nous tenons vivement à remercier :

Notre promotrice ***Dr. KHAOUANE Latifa****, Enseignante à L'UYFM, qui nous a extrêmement aidé et encouragé tout au long de ce travail. Nous lui devons les remerciements les plus sincères.*

Nous tenant à exprimer nos plus vif remerciements a notre Co-rapporteur ***Pr. HANINI Salah****, Professeur à l'UYFM, pour son aide, son accompagnent et ses éclairage technique.*

A tous nos collègues et amies qui nous ont soutenu et encouragé pour terminer ce travail et à toute la promotion Master 2020-2021.

Je tiens enfin à remercier toutes les personnes qui se sont intéressées de près ou de loin au projet.

Dédicace

A ***ma très chère mère***

Quoi que je fasse ou que je dise, je ne pourrais pas te remercier comme il se doit

Ton affection me couvre, ta bienveillance me guide et ta présence à mes cotés a toujours été ma source de force pour affronter les différents obstacles.

A

Mon très cher père

Tu as toujours été à mes côtés pour me soutenir et m'encourager

Que se travail traduit ma gratitude et mon affection.

A

Mes sœurs, mes belles ***Wassila, Ferial*** *et* ***Yasmine***

A

Mon binôme ***Zohra*** *avec qui j'ai partagé les difficultés de ce travail*
Puisse ALLAH vous donne la santé, bonheur, courage et surtout réussite

Manel

Dédicace

Je dédie ce modeste travail pour ma raison de vivre et c'est bien mes parents,Je commence par ***mon père****, mon premier amour, mon confident, je le remercie pour son sacrifices, son soutiens et pour sa présence,*

Et son oublié mon oxygène, ma moitié, ***ma chère maman*** *la source de l'amourla plus gentille et aimable de toute les femmes au monde que je ne pourrais jamais vivre son, que ALLAH vous garde pour moi et que ALLAH me donne la force pour vous récompensé le quart de ce que vous avez fais pour moi*

.Et

Je dédié encore une fois pour mes deux diamant mon plus beaux cadeaux dans ma vie

C'est mes frère: ***ABDELKAHAR*** *et* ***Mohamed*** *que ALLAH les protège*

A

MA SEULE SŒUR, MA MOITIE ***Soumia***

Et mes neveux ***Mohamed*** *&* ***Adam***

.A

Mes adorables copines ***Kaouthar , Iness, Imen ,Marwa ,Kenza, Ikram, Nassima, Houda et Sabrina***

A

La plus belle binôme ***Manel,*** *avec qui j'ai partagé les difficultés de ce travail*

Puisse ALLAH vous donne la santé, bonheur, courage et surtout réussite

A

Tous ceux qui me sont chers.
Tous ceux que j'ai omis de mentionné

ZOHRA

الملخص: نمذجة لزوجة السوائل بواسطة الشبكات العصبية الاصطناعية

تهدف هذه ا لدراسة إلى وضع تقنية ترتكز على شبكات الخلايا العصبونية الاصطناعية متعددة الطبقات (MLP) لتقدير لزوجة السوائل.

تم تقديم نموذج PMC-RNA للتنبؤ باللزوجة. الضغط الحرج ودرجة الحرارة الحرجة والكتلة المولية ودرجة الحرارة كمدخلات. يتميز النموذج العصبي المطور بالدقة الممتازة وتقديرات الخطأ شبه المثالية. معاملات الارتباط التي تم الحصول عليها في هذه الدراسات هي على التوالي (0.8304،0.8301،0.8301 ، 0.9472) لنتائج التعلم والاختبار والتحقق و الكلية بالإضافة إلى أن النتيجة تظهر تطابقًا متوسطًا تقريبًا مع البيانات التجريبية وتوضح أيضًا تحسنًا معنويًا مقارنةً بنموذج رياضي حديث متوفر في الأدبيات. توفر تنبؤات نموذج (PMC-RNA) أيضًا نظرة ثاقبة لتأثير درجة الحرارة الحرجة والضغط الحرج والكتلة المولية ودرجة الحرارة على قيم قياس اللزوجة.

في هذا السياق،قمنا بتطوير نموذج عصبي: حساب لزوجة السوائل (4-17-1): REQM = 1.4178).

كشفت هذه الدراسة عن دقة وكفاءة النماذج العصبية المصممة و المحسنة للتنبؤ بلزوجة السوائل.

الكلمات المفتاحية : نمذجة ،شبكات الخلايا العصبونية الاصطناعية،لزوجة،السوائل.

Résumé : *modélisation de la viscosité des liquides par les réseaux de neurones artificiels*

Le but de cette étude est la mise en œuvre d'une technique basée sur les réseaux de neurones artificiels de type perceptron multicouches (MLP), pour l'estimation de la viscosité des liquides.

Le modèle PMC-RNA est présenté pour la prédiction de viscosité. La pression critique, la température critique, la masse molaire et la température comme des entré. Le modèle neuronal développé se caractérise par une acceptable précision et des estimations d'erreur presque moyenne. Les coefficients de corrélation obtenus dans ces études sont respectivement (0,8301, 0, 8301, 0, 8304, 0,9472) pour les résultats de l'apprentissage, test et validation et totale de plus, le résultat montre une correspondance presque moyenne avec les données expérimentales et aussi démontre une amélioration significative par rapport à un modèle mathématique récent disponible dans la littérature. Les prédictions du modèle PMC-RNA donnent également un aperçu de l'influence de la température critique, de la pression critique et la masse molaire et la température sur les valeurs de mesure viscosité.

Dans ce contexte, nous avons développé un modèle neuronal : calcul de la viscosité des liquides (4-17-1) : REQM=1.4178).

Cette étude a révélé la précision et l'efficacité des modèles neuronaux conçus et optimisés pour la prédiction de la viscosité des liquides.

Mot clés **:** Modélisation, Réseaux de neurones artificiels, Viscosité, Liquides.

Abstract: modeling of the viscosity of liquids by artificial neural networks

The goal of this study is the implementation of a technique based on the artificial neural networks type multi-layer perception (MLP), for the estimation of the viscosity of and liquids.

The ANN-MLP model is presented for viscosity prediction. Critical pressure, critical temperature, molar mass and temperature as inputs. The developed neural model is characterized by excellent precision and almost perfect error estimates. The correlation coefficients obtained in these studies are respectively (0,8301, 0,8301, 0,8304, and 0,9472) for the results of learning, testing , validation and all. In addition, the result shows an almost average correspondence with the experimental data and also demonstrates an improvement significant compared to a recent mathematical model available in the literature. The predictions of the ANN-MLP model also provide insight into the influence of critical temperature, critical pressure, and molar mass and temperature on viscosity measurement values.

In this context, we have developed a neuronal model: calculation of the viscosity of liquids (4-17-1) : REQM = 1,4178).This study revealed the accuracy and efficiency of neural models designed and optimized for the prediction of fluid viscosity.

Keywords: Modeling, Artificial Neural Networks, Viscosity, Liquids.

Table des matières

Abréviation

Nomenclature

Liste de tableaux

Liste de figures

ChapitreI : Viscosité des liquides

I.1. Introduction....3

I.2. Les de viscosité 3

I.2. 1. La viscosité dynamique....3

I.2.2. La viscosité cinématique....4

I.3. Classification des fluides 4

I.3.1. Les fluides newtoniens 4

I.3.2. Les fluides non-newtoniens....5

I.3.2.1.Fluides non newtonien indépendant du temps de cisaillement 5

I.3.2.2. Fluides non newtonien dépendant du temps de cisaillement 7

I.4. Les types de l'Ecoulement....8

I.4. 1. Régime laminaire 8

I.4.2. Régime turbulent 8

I.5. Méthode de Mesure de viscosité : 9

I.5.1. Méthode directe par un viscosimètre : 10

I.5.1.1. Les viscosimètres à corps chutant :....10

I.5.1.2. Les viscosimètres à tube capillaire : 10

I.5.1.3.Les viscosimètres rotatifs : 11

I.5.1.4. Les viscosimètres à corps vibrants : 12

I.6. Objectif de la mesure de la viscosité 13

I.7. Paramètres dont dépend la viscosité....13

I.7.1. Expression de la viscosité en fonction de la température 13

I.8. Facteurs affectant la viscosité 15

I.8.1. Conditions de mesure 15

I.8.2. Température 15

I.8.3. Gradient de vitesse et force de cisaillement 15

I.8.4 Temps....15

I.9. Conclusion : 16

II.1. Introduction 17
II.2. Définition de réseau de neurone 17
II.3. Historique 18
II.4. Domaines d'application des réseaux de neurones artificiels 19
II.4.1. Modélisations prédictives 19
II.4.2. Capteurs virtuels 19
II.4.3. Reconnaissance des formes 20
II.4.4. Optimisation 20
II.4.5. Contrôle 20
II.5.Le Réseau de neurone biologique 20
II.5.1. Le neurone biologique 20
II.5.1.1. Définition 20
II.5.1.2. Corps Cellulaire 21
II.5.1.3. Axone 21
II.5.1.4. Dendrite 21
II.5.1.5. Synapses 22
II.5.1.6. Influx Nerveux 22
II.5.2. Fonctionnement du neurone biologique 22
II.6.Le Réseau de neurone artificiel 23
II.6.1. Neurone formel 23
II.6.2. Du neurone biologique au neurone formel 23
II.7.Caractéristiques des réseaux de neurones artificiels 25
a) Présentation 25
b) Les Entrées 25
c) Les fonctions d'activations 26
d) La sortie 26
II.8.Classification des réseaux de neurones 28
II.8.1. Classification selon la description architecturale 29
II.8.2. Classification selon les types d'apprentissages 30
II.8.2.1. Types d'apprentissage 30
I.9. Avantages des RNA 31
II.10. Techniques d'analyse et de validation des modèles de RNA. 31
II.10.1. Détermination des entrées/sorties du réseau de neurones 32
II.10.2 Choix et préparation des échantillons 32
II.10.3. Elaboration de la structure du réseau 32

II.10.4. Apprentissage 33
II.10.5. Validation et tests 33
II.11. Conclusion.....33
III.1. Introduction.....35
III.2. Méthodologie de calcul.....35
III.2.1. Elaboration de la base de données 35
III.2.1.1. Choix des entrées et sorties 36
III.2.1.2. Collecte des données.....37
III.2.1.3.Division de la base de données 38
III.2.1.4. Optimisation des architectures des RNA.....38
III.2.1.5. Choix du meilleur modèle 39
III.2.1.6. Performances du meilleur modèle développée 39
III.2.1.7. Analyse de sensibilité par la méthode de poids 40
III.3. Résultats et discussions 42
III.3.1. Architectures des modèles neuronaux.....42
Tableau III.4.Les résultats de l'optimisation des architectures des RNA 43
III.3.2. Expressions mathématiques du meilleur modèle neuronale obtenu 45
III.3.3. Estimation de la performance du meilleur modèle neuronale 46
III.3.3.1. Comparaison graphique entre les valeurs expérimentales et calculées.....46
III.3.3.2 Performance du meilleur modèle neuronale obtenu 49
III.4 Comparaison avec un travaille précédent 50
III.4.Conclusion 51

Conclusion général et perspectives…… 52

Références bibliographiques…… 54

BFGS **B**royden -**f**letcher-**G**oldfarb Shamno algorithm

MLP **M**ulti **L**ayer **P**erceptron

ERM **E**rreur **R**elative**M**oyenne

ESP **E**rreur **S**tandard de **P**rédiction

PMC **P**erceptron **M**ulti-**C**ouche

REQM **R**acine de l'**E**rreur **Q**uadratique **M**oyenne

RN **R**éseaux de **N**eurones

RNA **R**éseaux de **N**eurones **A**rtificiels

RNSO **R**éseaux de **N**eurones **S**tatique **O**ptimal

SOS **S**um **O**f **S**quares

CC **C**ouche **C**aché

CS **C**ouches **S**ortie

Caractères latins

Symbole	Signification	Unité
E_i	l'entrée i Représente du neurone.	(-)
F	la fonction d'activation (Seuil) du neurone	(-)
P_c	Pression critique	*[bar]*
T	Température	*[c°]*
T_c	Température critique	*[K]*
w_i	Poids synaptiques	(-)
R	Coefficient de régression	(-)
R^2	Coefficient de détermination	(-)

Caractères grecs

Symbole	Signification	Unité
ν	Viscosité cinématique	$[m2/\mathrm{s}]$
μ	Viscosité dynamique	$[kg/(m.s)]$
ρ	Masse volumique	$[kg\ /m^3]$

Indices	Exposants
C	Critique
M	Molaire
ρ	Pression

Liste des figures

Chapitre I. Viscosité des liquides

Figure I.1 Le comportement d'un fluide pseudo plastique…… 6

Figure I.2 Le comportement d'un fluide dilatant…… 7

Figure I.3 Le comportement d'un fluide plastique…….. 7

Figure I.4 Le comportement d'un fluide thixotropie…… 8

Figure I.5 Le comportement d'un fluide rhéopexie……. 9

Figure I.6 Types d'écoulement (laminaire, turbulent)……. 10

Figure I.7 Viscosimètre d'hoppler…… 11

Figure I.8 Viscosimètre d'Oswald…… 12

Figure I.9 Viscosimètre fungilab…….. 12

Figure I.10 Viscosimètre Brookfield…….. 13

Chapitre II. Réseaux de neurones artificiels

Figure II.1 Réseau de neurones artificiel à n variables d'entrée et une sortie…… 18

Figure II.2 Neurone biologique…….. 21

Figure II.3 Circulation de l'information de neurone…….. 22

Figure II.4 Structure générale du neurone formel…….. 23

Figure II.5 Les déférentes possibilités de classification des réseaux de neurones……. 28

Figure II.6 Réseaux multicouche MLP…….. 29

Figure II.7 Schéma générale de l'apprentissage supervisé…… 31

Figure II.8 Schéma générale de l'apprentissage non-supervisé……. 31

Chapitre III

Modélisation de la viscosité des liquides par les réseaux de neurones

Figure III.1 Capture d'écran pour le choix des fonctions d'activation sur STATISTICA. 40

Figure III.2 Organigramme illustrant l'analyse de sensibilité par la méthode de la partition des poids (méthode de poids) 43

Figure III.3 Représentation graphique du la meilleur division de la base des données. 45

Figure III.4 Représentation schématique d'un réseau du modèle de type PMC-RNA. 46

Figure III.5 Comparaison entre les valeurs de l'I expérimentales et celle calculées 50

Liste des Tableaux

Chapitre I

Viscosité des liquides

Tableau I.1 Viscosité de quelques composés d'après le catalogue HAAKE viscosimètres……..4

Chapitre II

Réseaux de neurones artificiels.

Tableau II.1 Équivalents RNA-RNB…… 25

Tableau II.2 Fonctions de transfert usuelles……. 27

Chapitre III

Modélisation de la viscosité des liquides par les réseaux de neurones

Tableau III.1 Liste des paramètres des entrées et de sortie……. 36

Tableau III.2 Liste des minimums et maximums des paramètres choisis…… 37

Tableau III.3 Liste des données d'entrée utilisée dans cette étude…….. 38

Tableau III.4 Les résultats de l'optimisation des architectures des RNA…… 44

Tableau III.5 Architecture du meilleur modèle obtenu…… 46

Tableau III.6. Poids et biais du RN optimal…… 46

Tableau III.7. Vecteurs de régression linéaire issue de l'équation linéaire ……. 50

Tableau III.8. Performance du meilleur modèle neuronale obtenu…….. 51

Introduction générale

La viscosité est une propriété intrinsèque des liquides nécessaire à l'étude de leur comportement mécanique. Dans l'industrie, la viscosité est fondamentale pour l'élaboration et la classification des fluides. Deux catégories de liquides se distinguent : les liquides newtoniens, et les non newtoniens. Les travaux réalisés montrent que la viscosité des liquides varie essentiellement avec la température (**Calchera .1999).**

La connaissance et la compréhension de la propriété de viscosité sont essentielles dans le domaine industriel, et plus généralement, en sciences. Cette propriété caractérise la facilité avec laquelle s'écoule un fluide dans une conduite ou dans toute autre situation plus anarchique telle que les mouvements de convection. En effet, cette dernière prend une place importante dans de nombreux procédés industriels faisant intervenir des écoulements de fluides lorsqu'ils sont utilisés comme fluides caloporteurs (H2O, Na dans les centrales nucléaires par exemple [Sobolev11, Abram08]**.** La viscosité est alors un des facteurs influant sur la valeur du débit d'un liquide. Dans ce contexte, on peut avoir intérêt à choisir un fluide plutôt qu'un autre car ses propriétés sont plus adaptées en vue d'une optimisation du dispositif. Le recours à des mélanges peut notamment permettre de se rapprocher du comportement désiré (utilisation d'alliages liquides dans les soupapes de moteur de voiture pour les refroidir, par exemple **(Nadège Meyer.2017).**

La détermination (ou le calcul) de la viscosité demeure une nécessité capitale pour la recherche scientifique et l'industrie. Les procédures expérimentales, empiriques et semi empiriques sont très délicates et difficile et prennent beaucoup de temps car elles ne se font que dans des laboratoires spécialisés. En revanche les approches théoriques, relativement accessibles, sont de plus en plus sollicitées pour l'estimation de ces propriétés de transport des gaz et des liquides d'une manière simple et à moindre coût. Mais la complexité et la nature de l'écoulement des gaz et des liquides n'ont fait qu'augmenter le défi **(Souraya *et al*.2013).**

L'objectif du présent mémoire est de développer une nouvelle approche basée sur les réseaux de neurones pour le calcul de la viscosité des liquides. Cette approche inspirée du traitement de l'information effectué par le cerveau, semble offrir un nouvel espace demodélisation tout à fait original. En effet, les réseaux de neurones artificiels (RNA) suscitent toujours un vif intérêt dans la plupart des domaines d'ingénierie non seulement pour leur attirante capacité d'apprentissage mais aussi pour leur flexibilité et leur bonne performance, par rapport aux approches classiques. Les RNA sont capables d'approximer des relations complexes et fortement non linéaires entre un vecteur de variables d'entrées x et une sortie y.

Dans cette étude nous avons développé un modèle neuronale de type perceptron multicouche pour prédire la viscosité en fonction de la température critique (Tc), la pression critique (Pc) et la masse moléculaire.

Le présent mémoire est organisé en trois chapitres :

Le premier chapitre comprend une étude bibliographique sur la viscosité des liquides, nous avons parlé sur des généralités et des notions de bases lier à ce sujet, tel que : la définition, les types des viscosités, les classifications des fluides et les types d'écoulement, les méthodes de mesure de viscosité, la présentation des paramètres dont dépend la viscosité.

Le second chapitre est consacré exclusivement à la présentation des réseaux de neurones d'une façon générale : historique, inspiration biologique, neurone formel, réseaux multicouches et règles d'apprentissage.

Le dernier chapitre sera consacré à la modélisation neuronale de la viscosité des liquides par les réseaux neuronale artificiel de type perceptron multi-couche Nous présenterons la méthodologie adopter pour la modélisation et les résultats obtenu.

Nous terminerons ce travail par une conclusion générale qui rassemble les principaux résultats obtenus et donne quelques perspectives qui seront un guide de référence pour les prochains travaux effectué dans cet axe de recherche.

Chapitre I

Viscosité des liquides.

I.1. Introduction

La viscosité (du latin vis cum, gui) est un paramètre important de la qualité de la plupart des produits finis. C'est une grandeur physique qui exprime la capacité d'un corps à s'opposer au cisaillement, peut être aussi définit comme la résistance à l'écoulement uniforme et sans turbulence se produisant dans la masse d'une matière **(Moussouni . 2017).**

La détermination de la viscosité de meure une nécessité capitale pour la recherche scientifique et l'industrie. Les procédures expérimentales sont très délicates et coûteuses et elles ne se font que dans des laboratoires spécialisés. En revanche les approches théoriques, relativement accessibles, sont de plus en plus sollicitées pour l'estimation de ces propriétés de transport des gaz et des liquides. Dans ce chapitre, nous définissons la viscosité et on donne leurs fondements théoriques.

I.2. Les de viscosité

I.2. 1. La viscosité dynamique

La viscosité dynamique η est le rapport des contraintes internes aux gradients de vitesse. Il s'agit de la résistance interne d'un fluide par rapport à son écoulement. Elle exprime donc l'intensité des contraintes mises en jeu lorsqu'on cisaille un fluide **(Messadi *et al.* 2011).**

L'unité pour la viscosité dynamique dans le système international est le « Pascal-seconde » (Pa.s). Fréquemment, on utilise aussi l'unité « milli Pascal-seconde » (mPa.s). D'anciennes unités sont toujours plus au moins utilisées, comme le poiseuille (Pl) (1 Pl = 1 Pa.s) ou bien le poise (Po) (1 Po = 0.1 PI = 0.1 Pa.s) **(Darwiche *et al.* 2012).**

Le terme de viscosité dynamique a la même signification que le mot viscosité absolue, viscosité de cisaillement ou viscosité tout simplement. Un avantage important de la viscosité absolue est que les résultats de la mesure ne dépendent pas des particularités du viscosimètre utilisé. On peut ainsi comparer les données des différentes techniques.

Les fluides dits Newtoniens ont une viscosité dynamique constante indépendante du gradient de vitesse. A titre d'exemple, on donne dans le tableau suivant quelques valeurs typiques de viscosité dynamique à 20°C en mPa.s pour différents fluides usuels **(Messaâdi *et al.*2011).**

Tableau I.1. Viscosité de quelques composés d'après le catalogue HAAKE viscosimètres.

Composé	Viscosité η (mPa.s)
Air	**1.7510^{-2}**
Mercure	**1.5**
Eau à 20°	**1**
Café crème	**10**
Huile d'olive	**10^2**
Miel	**10^4**
Goudron	**10^6**

I.2.2. La viscosité cinématique

La viscosité cinématique notée ν est déterminée en mesurant le temps qu'il faut à un fluide donné pour s'écouler dans un tube capillaire de section S par la force de gravité. Elle est donnée en $cm^2\ S^{-1}$. La viscosité cinématique est le quotient de la viscosité dynamique η par la masse volumique du fluide ρ, soit**:(MOUAS *et al*.2012).**

$$\boldsymbol{\nu = \frac{\mu}{\rho}} \qquad \textbf{(I.1)}$$

$\boldsymbol{\nu}$: $viscosité\ cinématique\ en\ m^2/s$.

$\boldsymbol{\mu}$: $viscosité\ dynamique en kg/(m.s)$.

$\boldsymbol{\rho}$: $masse volumique\ en\ kg\ /m^3$.

I.3. Classification des fluides

I.3.1. Les fluides newtoniens

Sont considères comme fluide newtoniens, l'ensemble des matériaux fluides dont la loi de comportement est conforme à la loi de newton qui établit une proportionnalité entre la contrainte de cisaillement et le gradient de vitesse de cisaillement **(Drissa *et al*. 2011 ; Sourdel *et al*.2018).**

Un fluide est dit newtonien dans le cas où les contraintes sont par définition des fonctions linéaires du taux de déformation du milieu **(Moumen *et al*.2010).**

Les fluides newtoniens ou complexes, interviennent dans de nombreuses applications de notre vie quotidienne, il intervient notamment dans les domaines agroalimentaires **(Sordel *et al*. 2018).**

I.3.2. Les fluides non-newtoniens

Les fluides non newtoniens ont la particularité d'avoir une viscosité variable en fonction de la vitesse et des contraintes qu'ils subissent. La viscosité diminue lorsque le gradient de vitesse augmente. Les fluides non newtoniens regroupent tous les fluides qui n'ont pas un comportement newtonien **(Gibouin *et al*. 2015).**

On distingue :

I.3.2.1.Fluides non newtonien indépendant du temps de cisaillement

Ce sont des fluides dans le temps de cisaillement n'a pas d'influence sur leurs comportements.

1 - Fluide de Bingham :

Les fluides plastiques idéals de Bingham sont des liquides qui ont besoin d'une contrainte critique pour s'écouler au-dessous de laquelle il n'y a aucun cisaillement possible et au-dessus de cette contrainte la courbe d'écoulement est une droite linéaire .la loi qui régit ce genre de fluide s'appelle le modèle de Binghame

$$\boldsymbol{\tau = \tau_0 + \mu_a \gamma} \qquad \textbf{(I.2)}$$

Avec : τ_0 Contrainte seuil d'écoulement.

μ_a viscosité plastique de Bingham.

2 - Fluide de Herschel-Bulkley :

La plupart des rhéogrammes des fluides viscoplastiques réels présentent un caractère rhéofluidifiant avec une contrainte critique, qui peut être représenté par la relation suivante :

$$\boldsymbol{\tau = \tau_0 + \mu_a \gamma^n} \qquad \textbf{(I.3)}$$

3 - Fluide fluidifiant ou pseudo plastique :

Il représente la majorité des fluides non newtoniens, ce sont des fluides qui ont tendance à ce fluidifié avec l'augmentation de cisaillement, ce qui se traduit par une diminution de leur viscosité.

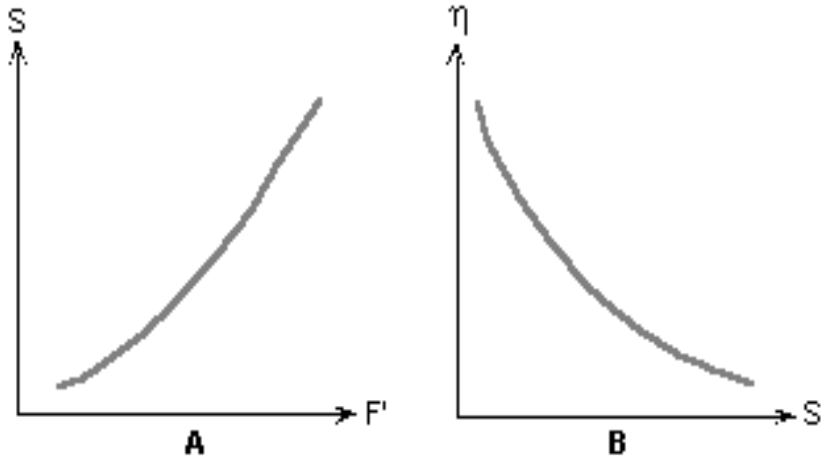


Figure I.1. : Le comportement d'un fluide pseudo plastiques (www.perso.latribu.com/shagar/steve/pdf/sa3.pdf).

4-Dilatant

Une viscosité croissante avec une augmentation du taux de cisaillement est caractéristique d'un fluide dilatant et ce comportement est illustré dans la figure ci-dessous.

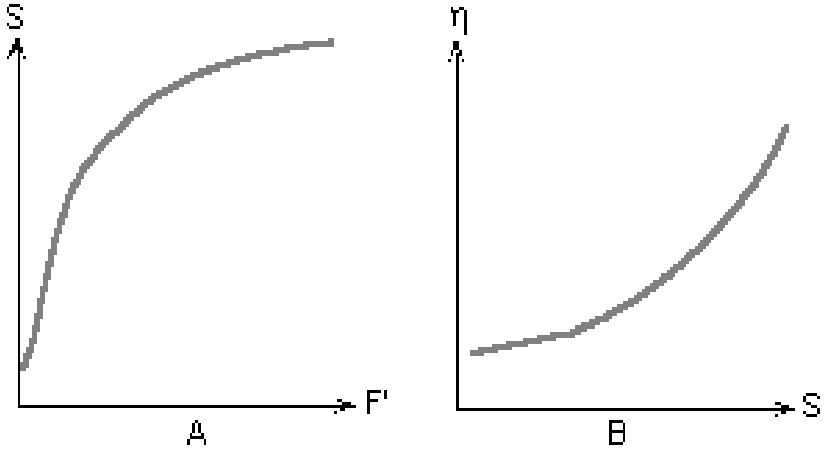


Figure I.2 : Le comportement d'un fluide dilatant (www.perso.latribu.com/shagar/steve/pdf/sa3.pdf).

5-Plastique :

Un tel comportement est fréquent : crèmes, chocolat, encre d'imprimerie pates, suspensions à forte concentration.

Tous ces substances apparaissent fluides après un seuil d'écoulement T à partir duquel leur viscosité décroît lorsque le gradient de vitesse augment (**Bellet R *et al.*1985).**

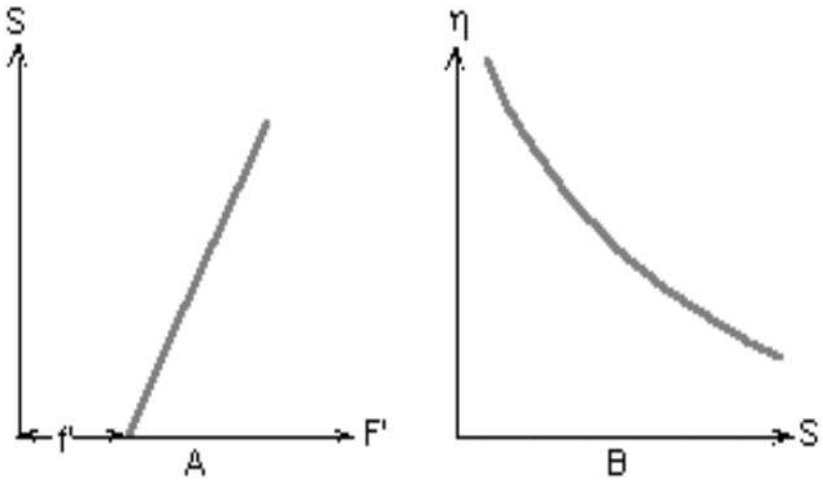


Figure I.3 : Le comportement d'un fluide plastique (www.perso.latribu.com/shagar/steve/pdf/sa3.pdf).

I.3.2.2. Fluides non newtonien dépendant du temps de cisaillement

Certains fluides non newtoniens subissant une variation de leurs propriétés d'écoulement en fonction du temps de cisaillement auquel ils sont soumis. Leur comportement dépend de l'historique des contraintes qu'ils ont subies. Ils correspondent aux fluides de Boltzmann. On y distingue essentiellement les fluides thixotropes et les fluides antis thixotrope **(Briant.J*et al*. 1985).**

1 - Les fluides thixotropes :

Une substance est dite thixotrope quand sa viscosité diminue avec le temps de cisaillement. Ceci s'explique par une modification, une destruction partielle de la structure du fluide. Au repos, la viscosité se rétablit progressivement **(Joël S*et al*. 2006).**

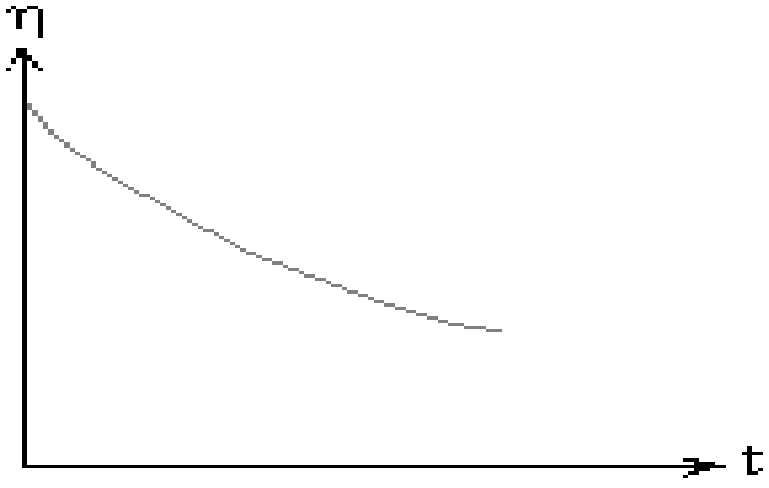


Figure I.4 : Le comportement d'une fluide thixotropie.

C'est essentiellement le comportement opposé du comportement thixotrope, en ce sens que la viscosité du fluide augmente avec le temps lorsqu'il est soumis à un taux de cisaillement constant. La figure ci-dessous représente graphiquement ce type de comportement.

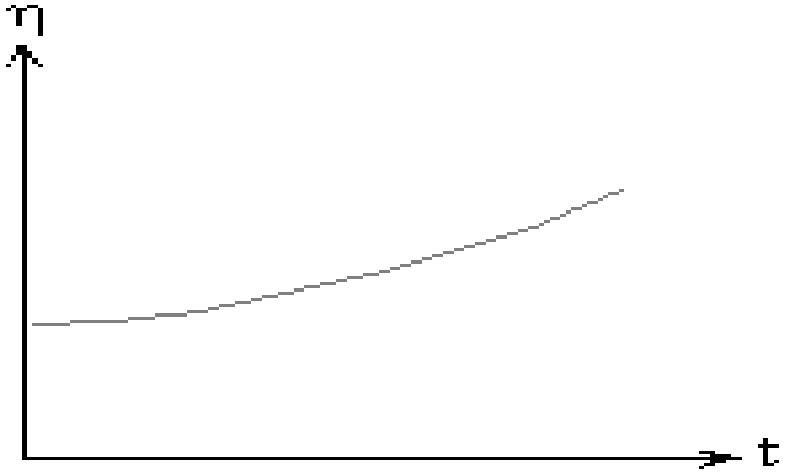


Figure I.5 : Le comportement d'un fluide rhéopexie
(www.perso.latribu.com/shagar/steve/pdf/sa3.pdf).

I.4. Les types de l'Ecoulement

I.4. 1. Régime laminaire

L'écoulement est laminaire, c'est-à-dire que sa vitesse ne présente pas de fluctuation, Un écoulement est dit laminaire lorsqu'il est régulier (qu'il ne présente pas trop de variations spatiales ou temporelles **(Abadier *et al*.2005).**

Dans ce cas toutes les particules se déplacent dans une direction parallèle au sens général de l'écoulement, ce qui veut dire que tous les vectrices vitesses individuelles sont parallèles entre eux et parallèles au vecteur vitesse moyenne **(Barka *et al*. 2016).**

I.4.2. Régime turbulent

Lors de l'étude du frottement en conduite que cette zone de régime de transition entre le régime laminaire et le régime turbulent dépend des conditions de rugosité de la paroi de la conduite **(BOUGROURA*et al*. 2006).**

Dans ce cas, Les vecteurs vitesses peuvent prendre toutes les directions, ce qui se traduit par l'apparition de tourbillons, mais la résultante de ces vitesses reste malgré tout dirigée dans le sens global de l'écoulement **(Barka *et al*. 2016).**

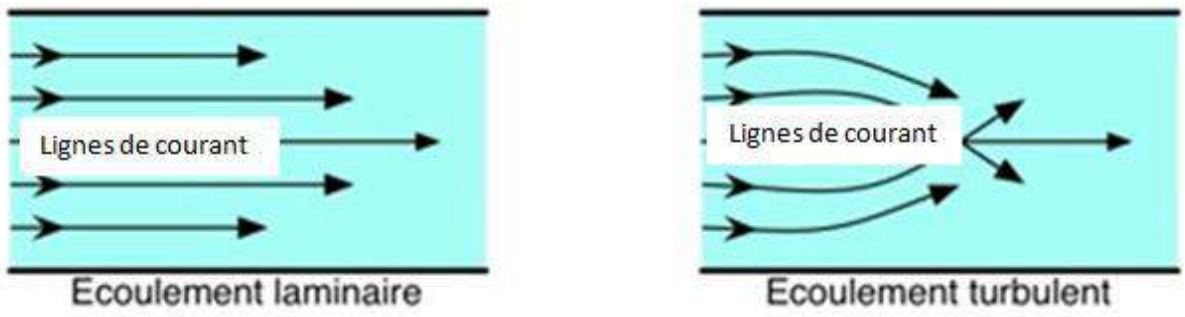


Figure I.6. Types d'écoulement (laminaire, turbulent)
(Abadier .2005).

- **Le nombre de Reynolds**

Le nombre de Reynolds est un nombre sans dimensions et selon les valeurs qu'il prend (dans le système international) on pourra caractériser la probabilité pour un écoulement d'être luminaire ou turbulent (**Badaoui f *al.* 2012).**

$$Re = \rho . Vm . D/\eta \qquad \textbf{(II.3)}$$

- Vm: la vitesse circulatoire moyenne.
- D : le diamètre du tuyau.
- ρ : la masse volumique du liquide
- η : la viscosité du liquide.

- Si Re < 2400 le régime est probablement laminaire

- Si Re > 3000 le régime est probablement turbulent

- Si 2400 > Re > 3000 le régime instable (intermédiaire), c'est à dire qu'il peut être aussi-bien laminaire que turbulent, en fonction des conditions extérieures **(Abadier .2005).**

I.5. Méthode de Mesure de viscosité :

En vue de comprendre les comportements d'un fluide complexe, les mesures de la viscosité classiquement faites en utilisent un viscosimètre, il s'agit de méthodes de mesure rapides et pratiques.

I.5.1. Méthode directe par un viscosimètre :

Il existe plusieurs types de viscosimètre comme : Le viscosimètre à corps chutant, le viscosimètre à corps vibrants et le viscosimètre à tube capillaire.

I.5.1.1. Les viscosimètres à corps chutant :

Sont généralement utilisés pour effectuer des mesures relatives en mesurant le temps de chute libre d'un corps solide dans un liquide sous l'influence de la gravité. Les viscosimètres les plus courants sont ceux à bille chutant verticalement ou à bille roulant sur un plan incliné (Ex : Viscosimètre d'Hoppler**) (Sandrine *et al*. 2008).**



Figure I.7. Viscosimètre d'Hoppler.

(https://www.es-france.com/)

I.5.1.2. Les viscosimètres à tube capillaire :

Ont comme avantages la simplicité de construction et l'utilisation sous pression atmosphérique. Le principe de ces viscosimètres est basé sur l'application de l'équation de poiseuille qui permet de calculer la viscosité d'un liquide qui s'écoule dans un tube circulaire de faible section à partir de son champ de vitesse, de la section du canal et d'autres paramètres connus de viscosimètre. Ce type permet d'étudier les systèmes newtoniens (Ex : viscosimètre d'Oswald, viscosimètre Hubbelohde) **(ADDIL*et al*. 1993).**



Figure I.8. Viscosimètre d'Oswald

(Addil *et al*.1993)

I.5.1.3.Les viscosimètres rotatifs :

Contrairement aux viscosimètres précédents, les appareils à mobile tournant (appelés aussi à géométrie variable) permettent de faire varier le taux (ou la tension) de cisaillement et ainsi d'étudier les systèmes newtoniens et non newtoniens.

Ces viscosimètres possèdent un ensemble de tiges de différentes géométries, de façon à obtenir la meilleure précision dans l'intervalle de viscosités du produit (ex : viscosimètre Brookfield, viscosimètre Fungilab) **(Addil *et al*. 1993).**



Figure I.9 Viscosimètre fungilab

(https://www.fishersci.fr/)



Figure I.10 Viscosimètre Brookfield

(https://labomat.eu/)

I.5.1.4. Les viscosimètres à corps vibrants :

Consistent à caractériser les déformations d'un corps solide (fil, lame) immergé dans un liquide. La viscosité du liquide sera calculée à partir des déformations apportées sur le solide par un courant électrique alternatif en présence d'un champ magnétique **(Sandrine *et al*. 2008).**



Figure I.11. Viscosimètre vibrant

(https://www.directindustry.fr/)

I.6. Objectif de la mesure de la viscosité

La raison fréquente justifiant des mesures de propriétés rhéologiques peut être trouvée dans le contrôle de qualité des produits liquides qui se doivent d'être uniformes et cohérents d'un lot à un autre. Pour cela, la mesure de la viscosité s'avère être une mesure indirecte du niveau d'homogénéité et de la qualité du produit **(Addil *et al*. 1993),** car elle conditionne l'écoulement des fluides dans la canalisation et le long des parois. Elle permet de mesurer directement ou indirectement certaines caractéristiques des produits (texture…etc.), Elle conditionne le bon fonctionnement des processus **(Harchelle . 1997).**

I.7. Paramètres dont dépend la viscosité

La viscosité dépend de plusieurs facteurs, citons par exemple la nature physico-chimique des molécules du milieu, la température et la pression du système, le gradient de vitesse de cisaillement ou d'écoulement, les contraintes mécaniques agissant sur le système et la durée au bout de laquelle les molécules seront soumises au cisaillement.

I.7.1. Expression de la viscosité en fonction de la température

La viscosité dépend fortement de la température. Aussi doit-on toujours, pour conserver un sens à la mesure, préciser la température à laquelle à été faite. Dans un liquide, la viscosité décroît rapidement en fonction de la température selon la loi suivante :

$$\eta = \eta_0 \cdot \frac{1}{1+\alpha.T+\beta.T^2} \quad \textbf{(I.4)}$$

Où η_0 la viscosité à T = 273 K.

Une loi de variation de type Arrhenius traduit la variation de la viscosité dynamique en fonction de la température en K :

$$\eta = A.\exp\left(\frac{Ea}{RT}\right) \quad \textbf{(I.5)}$$

Avec A est une constante indépendante de la température est équivalente à une énergie d'activation du flux visqueux. C'est l'énergie requise au voisinage proche d'une couche dans le liquide, provoquant un vide, dont se logent les molécules de la couche précédente.

Toutefois, Slack constate que la relation d'Arrhenius ne couvre pas un domaine assez large de température. Selon des études faites par Eicher et Zwolinski dans l'intervalle de température compris entre 263 à 423K, la viscosité est donnée par **(A.V. Slack, phosohoricacid ,1 (1968) 405.)**

$$\text{Ln}\frac{\eta_0}{\eta} = \frac{A(T-293)+B(T-293\ )}{c+T} \quad \textbf{(I.6)}$$

Avec A, B et C sont des constantes caractéristiques du mélange utilisé et la viscosité du solvant pur.

Autre équation similaire à celle d'Arrhenius est donnée par Andrade]. Davies et Matheson ont testé cette équation qui est de la forme suivante :

$$\text{Ln}\eta = lnA + \frac{Ea}{RT} \quad \textbf{(I.7)}$$

Cette équation tient compte de l'effet de la rotation des molécules sur la viscosité par le biais de$\Delta\ H$;

$\Delta\ H$: est l'enthalpie d'activation du flux visqueux, exprimé en cal.mol^{-1}. Cette dernière est similaire à celle d'Arrhenius. Etant donnée que cette enthalpie est reliée à l'enthalpie dévalorisation par :

$$\mathbf{Ea}=\frac{\Delta vapH}{n} \qquad \textbf{(I.8)}$$

Avec n est la fraction molaire du soluté. Le facteur A est donné par :

$$\mathbf{A}=\ln 1.09.10^{-3}.M^{1/2}.T^{3/2}/V^{3/2}\Delta Vevap \qquad \textbf{(I.9)}$$

Où M est la mase molaire du mélange et V le volume du mélange.

I.8. Facteurs affectant la viscosité

Il existe différentes variables qui affectent les propriétés rhéologiques des produits :

I.8.1. Conditions de mesure

Les conditions de mesure pendant la détermination de la viscosité peuvent avoir un effet considérable sur les résultats de cette mesure. Par conséquent, il est important de contrôler l'environnement ainsi que les conditions des échantillons à analyser. Certaines variables à l'instar le type de viscosimètre, la combinaison mobile/vitesse, le moyen de mesure (bécher), l'absence ou la présence de protecteur des mobiles, la température de l'échantillon, les techniques de préparation…etc. peuvent affecter non seulement la précision de la lecture, mais également la valeur finale de la viscosité**(Dealy et wang *et al.* 2013).**

I.8.2. Température

La température est sans doute le facteur le plus influent, à toucher le comportement rhéologique. L'effet de la température sur la viscosité est essentiel, notamment sur des fluides. Une élévation de la température du fluide de 1ºC peut varier jusqu'à 10% de la valeur de la viscosité **(Tabilou *et al*. 2013).**

I.8.3. Gradient de vitesse et force de cisaillement

Le fluide est soumis à une certaine force de cisaillement, il peut en être affecté et le gradient de vitesse décrira ce phénomène. Il faut donc connaître sa viscosité aux forces de cisaillement appliquées **(Messadi *et al.* 2011).**

I.8.4 Temps

Pour des fluides thixotropes et rhé pectiques et lors d'un quelconque mouvement du fluide, plus le temps passe, plus le fluide verra sa viscosité évoluée.

I.9. Conclusion :

Au terme de ce chapitre, nous pouvons conclure que ; le coefficient de transport, «la viscosité dynamique », bien que nécessaire pour l'étude des phénomènes de transport, une recherche dans le sens d'apporter une amélioration à la façon de leur estimation est plus que nécessaire au vu de leurs importances.

Cette préoccupation fera l'objet du chapitre suivant, où une nouvelle technique basée sur les réseaux de neurones artificiels, est mise à l'épreuve.

Chapitre II

Réseaux de neurones artificiels.

II.1. Introduction

Lors de l'émergence d'une nouvelle technique, l'ingénieur se demande naturellement en quoi elle peut lui être utile. S'elle est dotée d'un nom plus métaphorique que scientifique, ce qui est évidemment le cas pour les réseaux de neurones, dont le nom est lié fortement à la biologie.Alors techniquement parlant, les réseaux de neurones artificiels (RNA) sont de Nature purement mathématique et statistique ; leurs applications se situent dans des domaines qui a un rapport avec la neurobiologie.

Le domaine de calcul par réseaux de neurones a mûri au cours de la dernière décennie et a trouvé de nombreuses applications industrielles.

Les réseaux de neurones sont maintenant couramment utilisés dans les processus de contrôle, de fabrication, de contrôle de la qualité, de la conception du produit, d'analyse financière, de la détection des fraudes, de l'approbation du prêt, de la reconnaissance vocale et d'exploration de données **(Bendaoud .2014).**

II.2. Définition de réseau de neurone

Les réseaux de neurones artificiels sont des réseaux fortement 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 **(Claude *et al*.1992).**

Ces réseaux nécessitent la sélection des variables d'entrée 'xi 'ayant une influence sur la donnée "y" à modéliser. Ensuite, il s'agit de développer une fonction algébrique' f', Ceci sera développé à l'aide d'une modélisation, par régression non linéaire vis -à vis des paramètres de la fonction estimé utilisant les réseaux de neurones artificiels (RNA) **(figure I.1) (Hamadache .2014)**

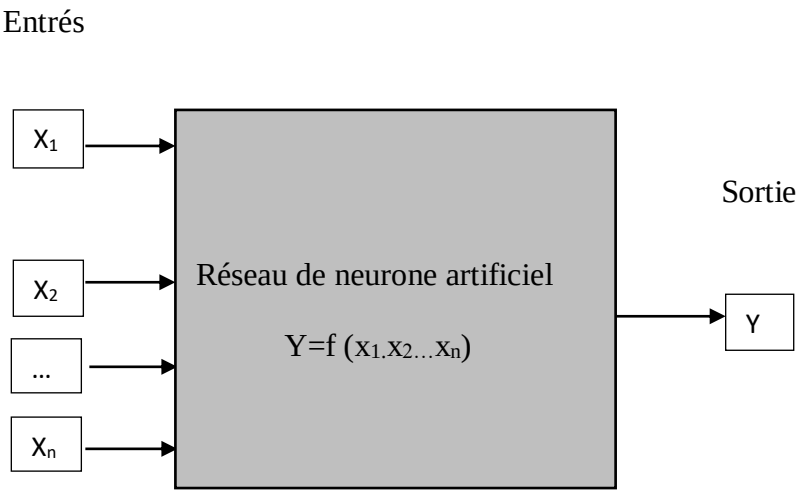


Figure II.1.Réseau de neurones artificiel à n variables d'entrée et une sortie **(hamadache 2014).**

II.3. Historique

En 1943 Mac Culloch et Pitts ont proposé le premier modèle de neurone biologique appeler aussi le modèle de neurone à seuil **(Davalo *et al.* 1989**), qui a été inspiré des récentes découvertes en biologie, ce sont des neurones logiques (0 ou 1), ils ont montré que les neurones formels peuvent réaliser des fonctions logiques. En 1949 le psychologue Donald Hebb a introduit le terme connexionnisme pour parler des modèles massivement parallèles et connectés, il a proposé de nombreuses règles de mise à jour des poids dont la plus connue à cette époque est la "règle de Hebb" **(Hebb 1949 :Davalo *et al*. 1989).**

En 1958 le psychologue Frank Rosenblatt a développé le modèle du perceptron **(Rosenblatt*et al*.1958)**, il s'agit d'un réseau de neurones inspiré du système visuel capable d'apprendre à différencier entre les formes simples et à calculer certaines fonctions logiques, il a connu un grand succès lorsqu'il a été appliqué dans le domaine de la reconnaissance des formes. Au début des années 60 les travaux de Rosenblatt ont vécu un grand intérêt dans le milieu scientifique. Cependant, en 1969 deux scientifiques américains appelés Minsky et Papert **(Minsky &Papert 1988 ; Davalo *et al.* 1989)** ont publié un livre dans lequel ont démontré les limites du perceptron proposé par Rosenblatt, en particulier son incapacité réside à la résolution des problèmes non linéaires.

Les travaux se sont ralentis considérablement jusqu'à les années 80, en 1982 Hopfield a fini par démontrer l'intérêt des réseaux entièrement connectés (**Hopfield 1982 ; Davalo *et al*. 1989).** Parallèlement Werbos a conçu un mécanisme d'apprentissage pour les réseaux multicouches de type perceptron appelé "la rétropropagation" (en anglais : back propagation), cet algorithme a

propagé l'erreur vers les couches cachées et il sera publié en 1986 dans un livre "Parallel Distributed Processing" par les deux auteurs Rumelhart et McClelland **(Rumelhart *et al*. 1986).**

En 1989 Moody et Darken **(Moody &Darken 1989)** exploitent quelques résultats de l'interpolation multi variables pour proposer le Réseau à Fonctions de Base Radiales (RFBR), connu sous le nom anglophone "Radial Basis Function network" (RBFN), ce type de réseau diffère des autres types de réseaux de neurones par sa représentation locale **(Talbi *et al*. 2011).**

II.4. Domaines d'application des réseaux de neurones artificiels

II.4.1. Modélisations prédictives

Plusieurs exemples ont été effectués dans la littérature sur la modélisation pour un but prédictive utilisant les RNA, tels que l'estimation des rendements en biomasse, en substrat comme le glucose et en produit l'éthanol par un réseau récurrent ayant comme entrées : les mesures antérieures, les conditions du processus et les entrées de commande du processus, étudié par Zhu et ces collaborateurs **(Zhu *et al*. 1996)**, ils ont utilisé un RNA pour décrire la production à grande échelle d'un produit à partir des mesures en ligne et la simulation récursive de la consommation du sucre. **(Galván *et al*. 1996)** ont utilisé les réseaux de neurones dans l'ajustement de données cinétiques complexes des réactions chimiques, ils ont démontré que cette modélisation s'avère très utile lorsque les mécanismes cinétiques ne sont pas bien saisis et que suffisamment de données sur des processus sont disponibles. Les RNA peuvent remplacer les modèles semi-mécanistiques, à cause de sa robustesse, sa facilité utilisation et sa rapidité de convergence **(Fontaine & Germain 2001).**

II.4.2. Capteurs virtuels

Les RNA sont aussi appliquées pour le développement des capteurs virtuels (en anglais : soft sensors) à des fins d'estimation et de contrôle, généralement les mesures on line sont reliées aux mesures "off line" des états des processus **(Di Massimo *et al*. 1992 ; Karim *et al*. 1997 ; Ye*et al*. 1998 ; Linko*et al*. 1999)**. En outre, les informations spécifiques du processus comme le temps de la fermentation peuvent être utilisées comme des inputs additionnels **(Di Massimo *et al*. 1992)**, les capteurs virtuels peuvent aussi être appliqués pour remplacer les procédures analytiques couteuses et compliqués. Kang et ces collaborateurs **(Kang *et al*. 1998)** ont développées un capteur virtuel pour la mesure de la concentration d'acide clavulanique, une autre innovation est le nez électronique **(Bachinger et Mandenius 2000).**

II.4.3. Reconnaissance des formes

La reconnaissance des formes (en anglais : pattern recognition) est une autre application des RNA, il s'agit d'une détection irrégularités du processus, afin de prédire de la performance Chapitre II. Techniques de modélisation neuronal et méthode de RQSP **Mémoire de fin d'étude master génie chimique** du processus et pour détecter les défauts des capteurs **(Glassey *et al.* 1997)**, dans l'étude de Huang et ces collaborateurs, un réseau neuronal auto associatif artificiel a été utilisé en ligne pour détecter les écarts par rapport à la fermentation normale des cellules "Streptomyces virginiae" productrices de l'antibiotique "virginiamycine**" (Huang *et al.* 2002).**

II.4.4. Optimisation

Les RNA ont été appliqués pour l'optimisation des milieux de culture en mode batch par kennedy et co-auteurs **(Kennedy *et al.* 1992 ; Kennedy & Spooner 1996)**, cela a entraîné une diminution significative des expériences par rapport à l'approche classique basée sur les plans d'expérience. La combinaison des RNA avec les algorithmes évolutionnaires, tels que les algorithmes génétiques, a donné la naissance des nouvelles approches qui ont prouvé son efficacité et sa robustesse dans l'optimisation des milieux de culture de Lactobacillus plantarum **(Desai *et al.* 2006).**

II.4.5. Contrôle

Les modèles développés par les RNA sont souvent appliquées au sein des schémas de contrôle, estimateurs d'état ou optimiseur, Schenker et Agarwal **(Schenker &Agarwal 1998)** ont étudié les différents types de structures neuronales pour le contrôle prédictif des réacteurs chimiques. Kovárová et ces collaborateurs **(Kovárová-Kovar*et al.* 2000)** ont utilisés un modèle neuronal qui combine l'optimisation en ligne pour l'adaptation de la trajectoire d'alimentation durant la production de riboflavine.

II.5.Le Réseau de neurone biologique

II.5.1. Le neurone biologique

II.5.1.1. Définition

Le cerveau humain contient un grand nombre de neurones (environ 100 milliards) fortement interconnectés (environ 1015 connexions) **(Colgi *et al* 1906; Mo costandi *et al* 2006**) constituant ainsi des réseaux de neurones. Un neurone est une cellule du système nerveux spécialisée dans la communication et le traitement d'informations, le terme de neurone fut introduit par Waldeyer.

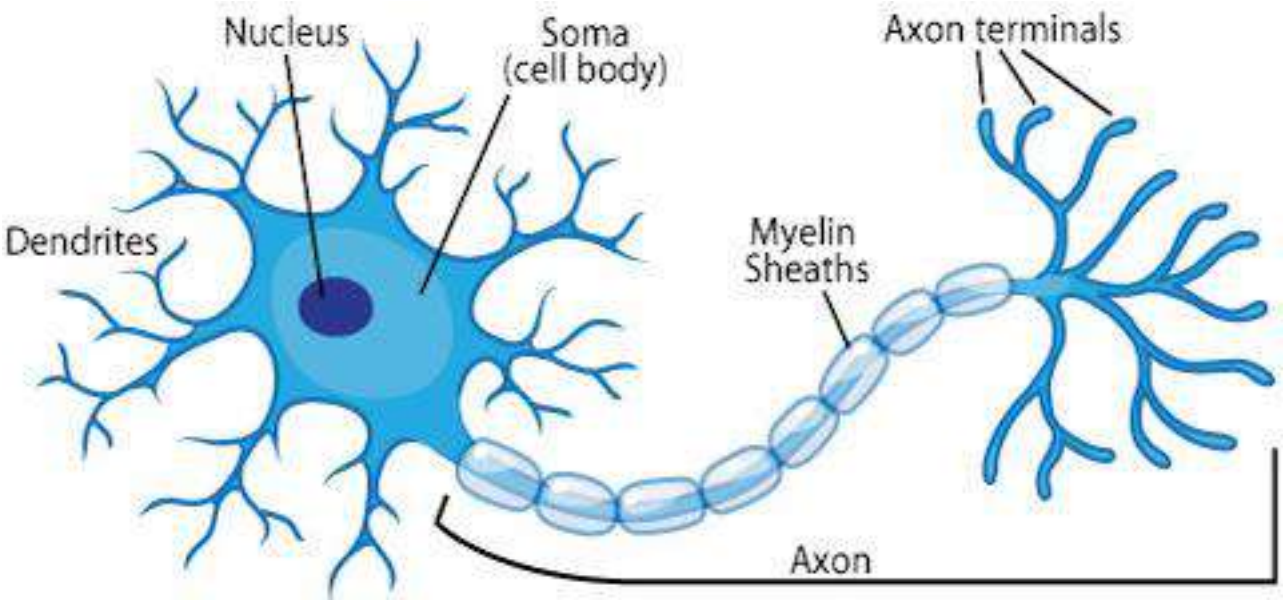


Figure II.2. Neurone biologique

https://askabiologist.asu.edu/neuron-anatomy

II.5.1.2. Corps Cellulaire

Souvent appelé " Le Soma" effectue la somme des informations qui lui parviennent, il traite ces mêmes informations et renvoie le résultat sous forme de signaux électriques vers les autres neurones à travers l'axone.

II.5.1.3. Axone

C'est un long prolongement fibreux du neurone, il fait la liaison entre les neurones et leurs conduit l'influx nerveux.

II.5.1.4. Dendrite

Joue le rôle de capteur, car il reçoit les informations venant de l'extérieur vers le corps cellulaire. Certaines dendrites peuvent avoir un effet moteur favorisant la transmission d'une information dans l'axone, d'autres au contraire ont un effet inhibiteur qui bloque la transmission de l'influx dans l'axone.

II.5.1.5. Synapses

C'est une zone située entre deux neurones (cellules nerveuses) et assurant la transmission des informations de l'une à l'autre.

II.5.1.6. Influx Nerveux

C'est une activité électrique qui parcourt les axones sous la forme d'une séquence de potentiel d'action, provocant la libération des neurotransmetteurs au niveau des synapses. Ces potentiels d'action sont générés par des échanges d'ions entre l'intérieur et l'extérieur des neurones. La vitesse de propagation de l'influx nerveux est de 100m/s.

II.5.2. Fonctionnement du neurone biologique

Les dendrites reçoivent des autres neurones, des informations sous forme de signal électrique (influx nerveux), elles seront envoyées vers le corps cellulaire (Soma) et plus précisément le noyau qui fera la somme des influx arrivant aux dendrites tout en affectant des poids dits " poids synaptiques » (**GANA Massine*et al.*2016).**

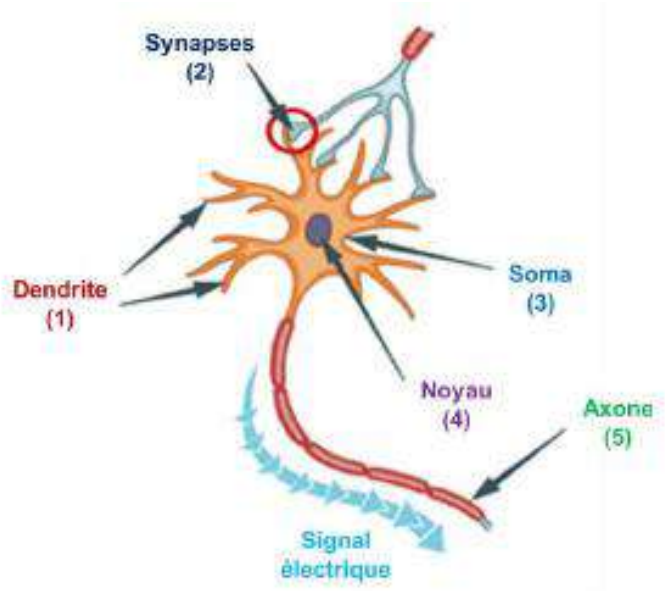


Figure II.3. Circulation de l'information de neurone.

(Roubehie Fissa .2021)

II.6.Le Réseau de neurone artificiel

II.6.1. Neurone formel

Par définition un neurone formel (figureII.4) est une fonction algébrique non linéaire, paramétrée, à valeurs bornées (**Dreyfus, G**). Il peut être caractérisé par :

a) La nature de ses entrées (x1, x2…, xi…, xn), qui peuvent être les entrées du réseau ou les sorties d'autres neurones du même réseau.

b) La fonction d'entrée totale définissant le prétraitement (combinaison linéaire) effectué sur les entrées comme ∑ Wi. xi +b , dont Wi est le poids synaptique attaché à l'entrée i et le b désigne le seuil d'activation (biais).

c) Sa fonction d'activation, ou d'état f, définissant l'état interne du neurone en fonction de son entrée totale. Cette fonction peut prendre plusieurs formes.

d) Sa fonction de sortie calculant la sortie du neurone en fonction de son état d'activation

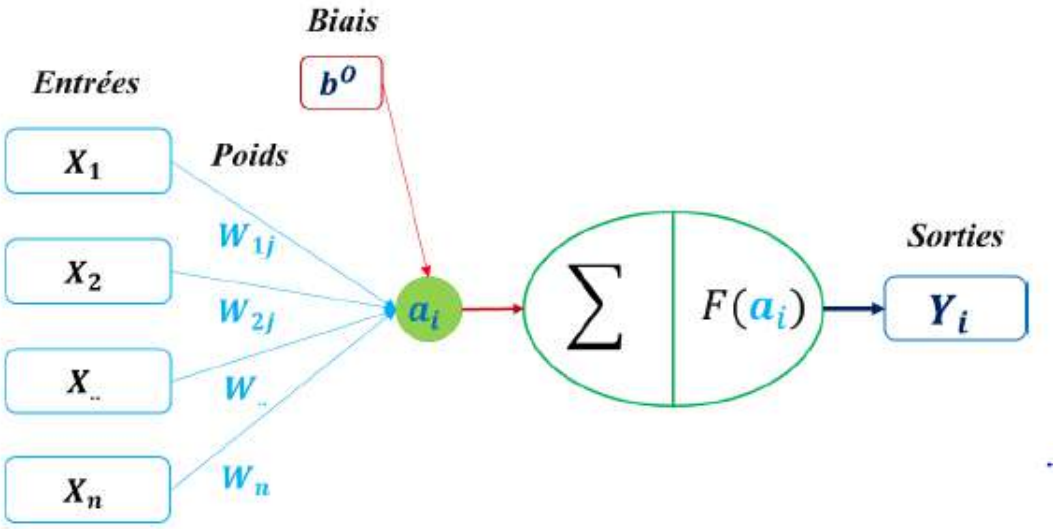


Figure II.4. Structure générale du neurone formel.

(Roubehie Fissa .2021)

II.6.2. Du neurone biologique au neurone formel

Si nous essayons d'interpréter autrement le fonctionnement précédent du neurone biologique, on pourrait dire que le noyau fait la somme du produit des informations acquis par les dendrites et

les poids attribués a ces mêmes informations, ensuite le corps cellulaire analyse le résultat, si ce dernier est supérieur à un seuil, il sera envoyé vers l'axone qui, soit ce subdivisera pour alimenter d'autres neurones, soit à attaquer un élément moteur (muscle par exemple); **(MCCulloch et Pitts**), furent les premiers à mettre en œuvre les réseaux de neurones, ils ont résumé cette approche mathématique par l'équation du neurone formel **(Kiyoshi *et al*.2000).**

$$\mathbf{S=F(}\sum_{i=1}^{n} w_i \ E_i\mathbf{)} \qquad \textbf{(II.1)}$$

où :

E_i : l'entrée i Représente du neurone.

ω_i: Représente le poids attribué à l'entrée i.

F : Représente la fonction d'activation (Seuil) du neurone {1 si F(x) > θ ; 0 sinon }, avec θ : Seuil.

S : Sortie du neurone.

On en déduit l'équivalence suivante qui illustrie dans le tableau suivant :

Tableau II.1.Équivalents RNA-RNB **(Gana massine *et al* .2016)**

Réseaux de neurones biologiques	Réseaux de neurones Artificielle
Soma	Neurone
Dendrite	Entré
Axone	Sortie
Synapse	Poids

II.7.Caractéristiques des réseaux de neurones artificiels

a) Présentation

Les réseaux de neurones artificiels sont donc des modèles inspirés du fonctionnement du cerveau humain, dans le but est de concevoir des machines capables de, non d'imiter, mais de se rapprocher au maximum du comportement de l'intelligence dont disposent les êtres humains, d'où la notion de "Intelligence Artificielle".

b) Les Entrées

Chaque réseau possède plusieurs entrées, chaque couche contient plusieurs neurone on note E_i ($1 \leq i \leq n$) les entrées du réseau, avec: nombre de neurones d'entrées; et à chacune d'entre elle on affecte un poids ωi , on y ajoute un coefficient dit "biais" $\omega 0$ supposé lié à une entrée E0 = 1, la i -ème information qui parviendra au neurone est le produit ωi x Ei . Le neurone calculera la somme : ωi x $Eini$=1,

Celle-ci sera le potentiel du neurone, la sortie sera générée par une fonction d'activation, qui sera très importante.

Le neurone calculera la somme : ωi x $Eini$=1, celle-ci sera le potentiel du neurone, la sortie sera générée par une fonction d'activation, qui sera très importante car elle déterminera par la suite le fonctionnement du réseau.ar elle déterminera par la suite le fonctionnement du réseau.

c) Les fonctions d'activations

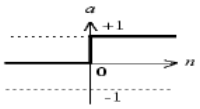
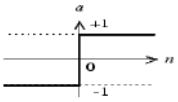
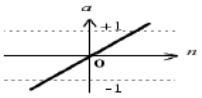
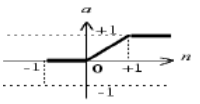
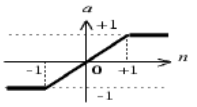
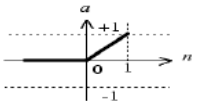
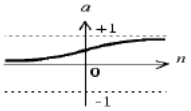
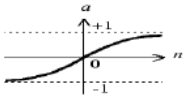
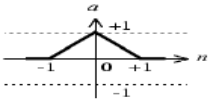
La fonction d'activation, ou fonction de transfert, est une fonction qui doit renvoyer un réel proche de 1 quand les "bonnes" informations d'entrée sont données et un réel proche de 0 quand elles sont "mauvaises". On utilise généralement des fonctions à valeurs dans l'intervalle réel [0 ;1]. Quand le réel est proche de 1, on dit que l'unité (le neurone) est **active** alors que quand le réel est proche de 0, on dit que l'unité est **inactive(Alp Mes tan)**. Elle peut prendre de nombreuses formes : binaire, linéaire, sigmoïde, et bien d'autres encore. Le tableau ci-dessous dévoile les fonctions d'activations les plus utilisées :

d) **La sortie**

Peut-être utiliser en tant que résultat final, ou pour alimenter d'autres neurones

le tableau suivant permet de connaitre les différences fonction usuelles

Tableau. II.2 Fonctions de transfert usuelles, $a=f(n)$ **(Si-Moussa *et al*.2009)**.

Nom de la fonction	Relation entrée/sortie	Graphe de la Fonction	Fonction dans MATLAB®
Seuil	$a=0$ si $n<0$ $a=1$ si $n\geq 0$		hardlim
Seuil symétrique	$a=-1$ si $n<0$ $a=1$ si n ≥ 0		hardlims
Linéaire	$a=n$		purelin
Linéaire saturée	$a=0$ si $n<0$ $a=n$ si $0\leq n\leq 1$ $a=1$ si $n>1$		satlin
Linéaire saturée symétrique	$a=-1$ si $n<-1$ $a=n$ si $-1\leq n\leq 1$ $a=1$ si $n>1$		satlins
Linéaire positive	$a=0$ si $n<0$ $a=1$ si $n\geq 0$		poslin
Logistique (Sigmoïde logarithmique	$a=\frac{1}{1+e^{-n}}$		logsig
Tangente hyperbolique	$a=\frac{e^{+n}-e^{-n}}{e^{+n}+e^{-n}}$		tansig
Triangulaire de base	$a=1-\lvert n\rvert$,-1 $\leq n\leq +1$ $a=0$, autrement		tribas

II.8.Classification des réseaux de neurones

Selon l'architecture on peut classer les réseaux de neurones en trois grandes catégories :

- Les réseaux de neurones Bouclés.
- Les réseaux de neurones Non-bouclés.

classer les réseaux de neurones en deux grandes catégories :

- Apprentissage supervisé.
- Apprentissage non supervisé.

La figure **(II.5)** résume les différentes possibilités suivantes lesquelles on peut classer les réseaux de neurones**(MOUSSAOUI et al.2021).**

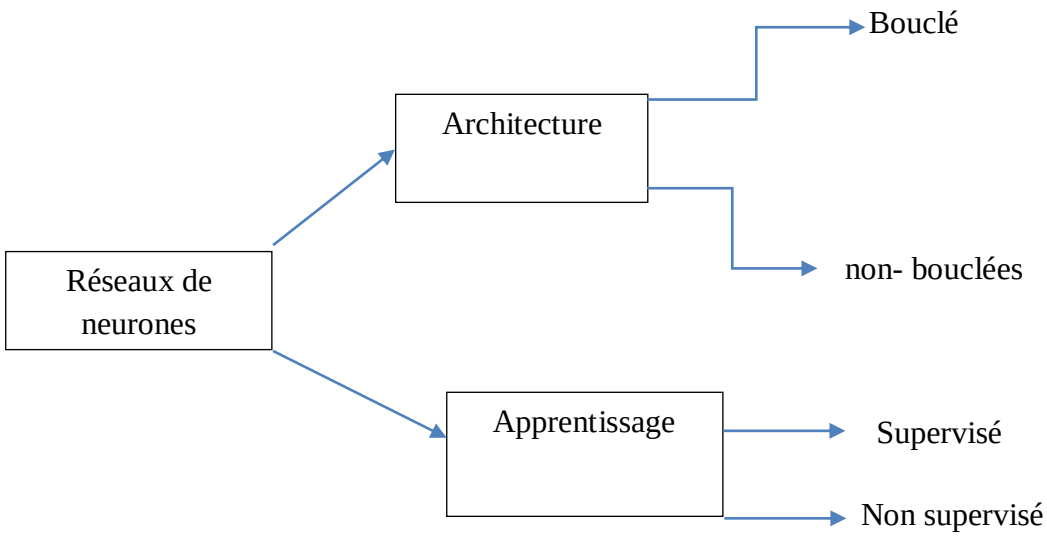


Figure II.5. Les déférentes possibilités de classification des réseaux de neurones**. (Moussaoui *et al* .2021)**

II.8.1. Classification selon la description architecturale

La façon dont les neurones artificiels individuels sont interconnectés est appelée topologie, architecture ou graphe d'un réseau de neurone artificiel **(Suzuki 2011)**. L'architecture d'un RNA désigne aussi toutes ces caractéristiques de fonctionnement de base telles que : le nombre d'entrées et de sorties, direction de signe d'information, positionnement des éléments de connexion (poids et biais), leur comportement et le mode d'interconnexion entre les neurones **(Dreyfus *et al.* 2002 ; Dreyfus 2005 ; Jain *et al.* 1996 ; Suzuki 2011)**. Le fait que l'interconnexion peut se faire de nombreuses façons dans les résultats de nombreuses topologies possibles, qui sont divisées en deux grandes familles de base, indiqué dans la **Figure II.5**, où :

- Le côté droit de la figure représente les réseaux de neurones bouclés (en anglais : *Recurrent/Feed-back Networks*), qui ont une topologie récurrente simple (graphe semicyclique), où une partie des informations circulent non seulement dans la direction de l'entrée vers la sortie, mais également dans le sens opposé **(Jain *et al.* 1996 ; Suzuki 2011)**.
- Le côté gauche de la figure représente les réseaux de neurones non-bouclés (en anglais : *Feed-forward Networks*), qui ont une topologie à action directe simple (graphe acyclique), dans lequel les flux d'informations circulant à partir des entrées vers les sorties dans une seule direction sans retour en arrière **(Dreyfus *et al.* 2002 ; Dreyfus 2005 ; Chamekh 2007)**.

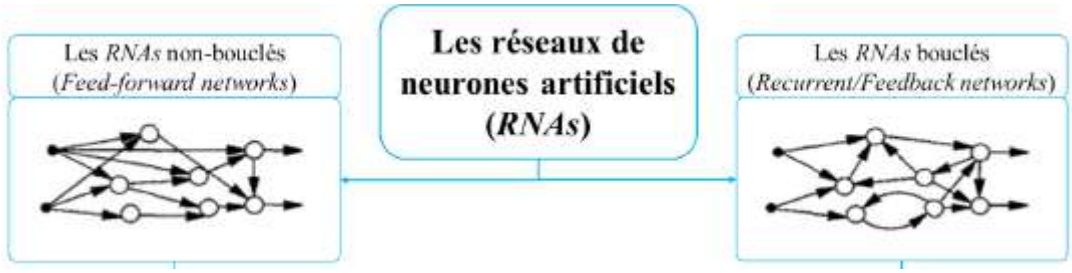


Figure II.6. Classification des réseaux de neurones artificiels selon les architectures d'interconnexions entre neurones **(Jain *et al.* 1996 ; Basheer & Hajmeer 2000 ; Bitam 2018)**.

II.8.2. Classification selon les types d'apprentissages

L'apprentissage automatique est utilisé pour doter les ordinateurs et les machines de systèmes de vision ; reconnaissance d'objets (visages, langages naturels, écriture...) ; aide aux diagnostics, médical notamment ; classification des séquences d'ADN ...etc **(gana massine*et al*.2016).**

II.8.2.1. Types d'apprentissage

Il présente plusieurs types, les plus utilisés sont :

L'apprentissage Supervisée :

Consiste en l'introduction de plusieurs données (attributs et étiquettes) déjà définies et étudiés par un expert ; pour la première phase, le réseau apprend ces échantillons en minimisant l'erreur entre la sortie désirée et celle obtenue, vient ensuite la deuxième phase où le réseau prédit la sortie selon ce qu'il a appris auparavant **(Gana massine .2016).**

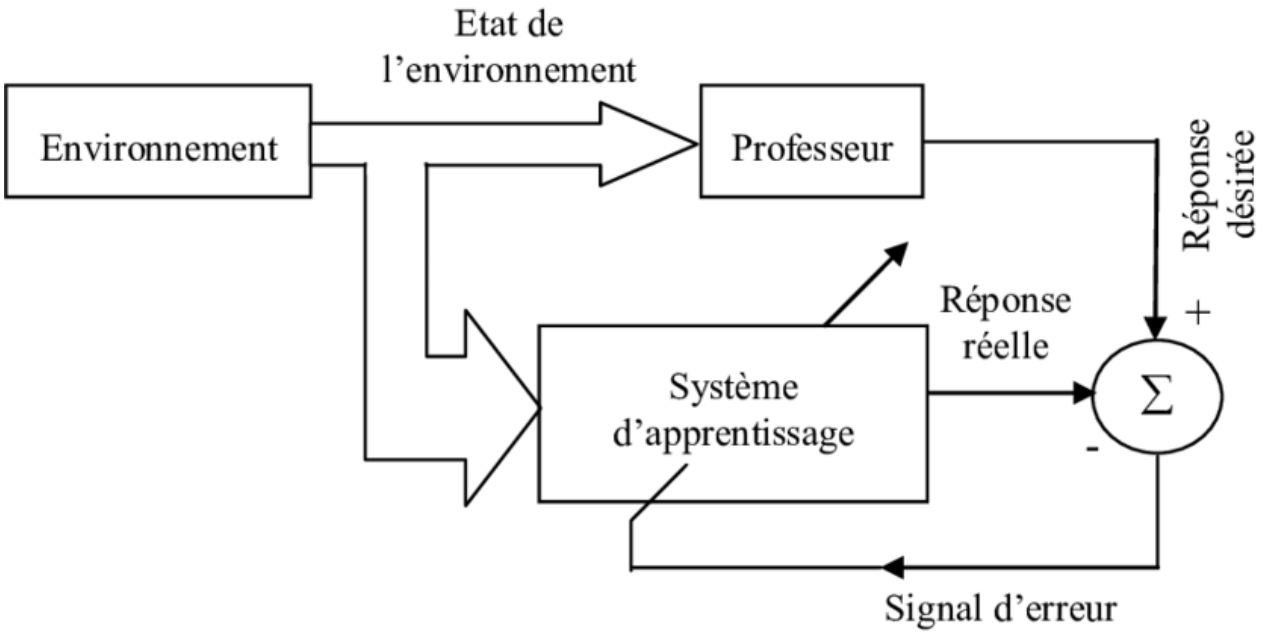


Figure II.7. Schéma générale de l'apprentissage supervisé.

- L'apprentissage Non - Supervisée :

Comme son nom l'indique, il est l'opposé du premier. Dans cet apprentissage, l'algorithme ne possède pas d'étiquettes, il va essayer de les deviner : il est autodidacte. Il va procéder par regroupement en cherchant les données similaires. Il est utilisé lorsque on ne sait ce que qu'on

cherche, Il est aussi appelé « Clustering », qui signifie « groupement » **(Gana massine*et al* .2016).**

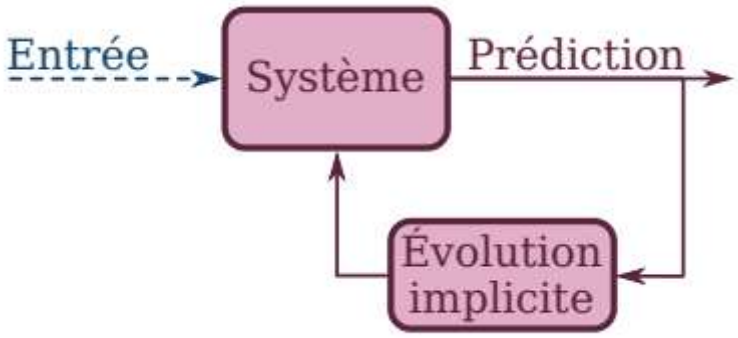


Figure II.8. Schéma générale de l'apprentissage non-supervisé.

I.9. Avantages des RNA

Les RNA fonctionnent sans programme, n'exécutent pas d'instructions, et ne manipulent pas de nombres. La destruction d'une partie de ces circuits n'empêche pas le réseau de fonctionner. Ces principales propriétés sont :

•**Parallélisme :** c'est l'exécution de plusieurs taches (données numériques et non pas symboliques) en même temps, ce qui explique la grande rapidité de calcul des RNA.

•**Capacité d'apprentissage :** elle permet aux réseaux de tenir compte des contraintes et des données provenant de l'extérieur. Elle se caractérise dans certains réseaux par leur capacité d'auto-organisation qui assure leur stabilité.

•**Généralisation :** elle permet au réseau de trouver une solution généralisée applicable à tous les exemples du problème, même s'ils contiennent des erreurs ou sont inachevés ou ne sont pas présentés pendant l'apprentissage.

• **Mémoire distribuée** : la mémoire est répartie sur plusieurs entités et sur tout le réseau.

II.10. Techniques d'analyse et de validation des modèles de RNA.

Les réseaux de neurones réalisent des fonctions non linéaires paramétrées. Leurs mises en œuvre nécessitent **(Si-Moussa . 2010)** :

• La détermination des entrées et des sorties pertinentes, c'est à dire les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser.

La collecte des données nécessaires à l'apprentissage et à l'évaluation des performances du réseau de neurones.

• La détermination du nombre de neurones cachés nécessaires pour obtenir une approximation satisfaisante.

• La réalisation de l'apprentissage.

• L'évaluation des performances du réseau de neurones à l'issue de l'apprentissage.

II.10.1. Détermination des entrées/sorties du réseau de neurones

Pour toute conception de modèle la sélection des entrées doit prendre en compte deux points essentiels **(Si-Moussa . 2010)** : Premièrement, la dimension intrinsèque du vecteur des entrées doit être aussi petite que possible, en d'autres termes, la représentation des entrées doit être la plus compacte possible, tout en conservant pour l'essentiel la même quantité d'information, et en gardant à l'esprit que les différentes entrées doivent être indépendantes.

En second lieu, toutes les informations présentées dans les entrées doivent être pertinentes pour la grandeur que l'on cherche à modéliser : elles doivent donc avoir une influence réelle sur la valeur de la sortie.

II.10.2 Choix et préparation des échantillons

Le processus d'élaboration d'un réseau de neurones commence toujours par le choix et la préparation des échantillons de données. La façon dont se présente l'échantillon conditionne le type de réseau, le nombre de cellules d'entrée, le nombre de cellules de sortie et la façon dont il faudra mener l'apprentissage, les tests et la validation **(Bishop *et al*. 1995).**

Il faut donc déterminer les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser. Lorsque la grandeur que l'on veut modéliser dépend de nombreux facteurs, c'est-à-dire lorsque le modèle possède de nombreuses entrées, il n'est pas possible de réaliser un pavage régulier dans tout le domaine de variation des entrées : il faut donc trouver une méthode permettant de réaliser uniquement des expériences qui apportent une information significative pour l'apprentissage du modèle. Cet objectif peut être obtenu en mettant en œuvre un plan d'expériences. Pour les modèles linéaires, l'élaboration de plans d'expériences est bien maîtrisée, par ailleurs, ce n'est pas le cas pour les modèles non linéaires (**Bitam *et al*.2018).**

II.10.3. Elaboration de la structure du réseau

La structure du réseau dépend étroitement du type des échantillons. Il faut d'abord choisir le type de réseau : Un perceptron standard, un réseau de Hop Field, un réseau à décalage temporel (TDNN), un réseau de Kohonen, un ARTMAP etc... Par exemple, dans le cas du perceptron multicouches, il faudra aussi bien choisir le nombre de couches cachées que le nombre de neurones dans cette couche **(Si-Moussa . 2010 & Hamadache .2014).**

II.10.4. Apprentissage

L'apprentissage est un problème numérique d'optimisation. Il consiste à calculer les pondérations optimales des différentes liaisons, en utilisant un échantillon. La méthode la plus utilisée est la rétropropagation, qui est généralement plus économe que les autres en termes de nombres d'opérations arithmétiques à effectuer pour évaluer le gradient. Pour rendre l'optimisation plus performante, on peut utiliser des méthodes de second ordre. Le calcul est très efficace, mais lourd. Elles ont de nombreuses limitations, quant aux conditions de convergence, sur les dérivées secondes. Des corrections sont proposées pour éviter ce problème, et sont prises en compte par les méthodes dites de Quasi-Newton ou de Newton modifiée **(Si-Moussa .2010).**

II.10.5. Validation et tests

Alors que les tests concernent la vérification des performances d'un réseau de neurones hors échantillon et sa capacité de généralisation, la validation est parfois utilisée lors de l'apprentissage. Une fois le réseau de neurones développé, des tests s'impose afin de vérifier la qualité des prévisions du modèle neuronal **(Hamadache *et al.* 2014).**

Cette dernière étape doit permettre d'estimer la qualité du réseau obtenu en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage. Une validation rigoureuse du modèle développé se traduit par une proportion importante de prédictions exactes sur l'ensemble de la validation. Si les performances du réseau ne sont pas satisfaisantes, il faudra, soit modifier l'architecture du réseau, soit modifier la base d'apprentissage **(Hamadache *et al*. 2014).**

II.11. Conclusion

Dans ce chapitre, on a étudié les réseaux de neurones de manière générale. Et on a montré leur origine, leurs différents modes et architectures dont ils disposent, on a aussi vu leur classification selon l'architecture ou le mode d'apprentissage, ainsi que leurs avantages.

Chapitre III

Modélisation de la viscosité des liquides par les réseaux de neurones

III.1. Introduction

Le calcule de la viscosité des liquides a permis d'établir des formules pour leurs calculs dont l'application certes valable, mais très astreignante parce qu'elles comportent plusieurs paramètres souvent très difficile à rassembler. C'est précisément dans ce contexte, que nous avons voulu apporter une alternative en proposant cette étude, dont l'objectif, est la mise en œuvre d'une méthode pratique de calcul basée sur les réseaux de neurones artificiels de type perceptron multicouche (PMC) et en utilisant des données usuelles souvent disponibles dans la littérature, afin d'approcher ces paramètres avec une erreur acceptable.

Les réseaux de neurones multicouches de type non bouclés, dont l'apprentissage est supervisé constituent une technique relativement récente de modélisation (boite noire) qui a montré ses performances. Il suffit d'avoir un ensemble de variables mesurées et d'un ensemble de mesures d'une grandeur de nature quelconque et en supposant qu'il existe une relation suffisamment régulière entre les variables et la grandeur alors, il est possible d'approximer cette relation par un réseau de neurone non bouclé **(Dreyfus *et al* 2002).**

Dans ce chapitre nous présentons la modélisation neuronale de la viscosité des liquides par les réseaux de neurones artificiels. Ce chapitre est divisé en trois parties :

- la première partie concerne l'élaboration de la base de données.
- Dans la deuxième partie on présentera la méthodologie de la modélisation neuronale de la viscosité des liquides.
- Dans la troisième partie on discutera les résultats obtenu et on étudie la contribution des variables d'entrée sur la viscosité (analyse de sensibilité).

III.2. Méthodologie de calcul

III.2.1. Elaboration de la base de données

Les étapes les plus importantes dans le développement du modèle neuronal suggéré est la disponibilité des données expérimentales fiables pour la formation du modèle. Ces données incluent des données éditées expérimentales sur la température critique, poids moléculaire et la pression critique des composants aussi bien que la viscosité aux différentes températures. En cette étude, 340 données expérimentales ont été rassemblées de différentes littératures **(Bourekba .2013 ; Viswanath et al. 2007)**

Dans le but de constituer une base de données fiable et représentative, nous avons suivi une méthodologie, inspirée de l'étude bibliographique **(Dreyfus *et al* 2002)**, qui revêt les étapes suivantes :

- Sélection des entrées du modèle neuronal;
- Collecte des données;
- Mise en forme des données; **(Bourekba *et al*.2013)**

III.2.1.1. Choix des entrées et sorties

La sélection des entrées consiste à déterminer les variables pertinentes par rapport à la grandeur à modéliser. Elle vise deux points essentiels **(Dreyfus *et al* 2002)** :

- Réduction de la dimension de l'espace de représentation des variables du modèle,
- Elimination des entrées qui n'ont pas ou peu d'influence sur la sortie.

Il est important de mentionner que chaque ajout d'une variable encombre le modèle et entraîne une multiplication des paramètres du réseau. Raison pour laquelle, la représentation des entrées doit contenir tous les facteurs pertinents par rapport à la grandeur à modéliser.

On a choisi dans cette étude de travailler avec les entrées et la sortie illustrée dans le tableau III.1. Le tableau III.2. Résume les minimums et maximum des paramètres choisis.

Tableau III.1. Liste des paramètres des entrées et de sortie

;

Tableau III.2. l'intervalle des paramètres de la base de données

	Propriétés	**Minimum**	**Maximum**
Entrés	***T (c°)***	0	40
	T_c (K)	233.700	1080.240
	M (g/mol)	17.03	863.75
	P_c (bar)	2.4	113.57
Sortie	***η (cP)***	0.00120	19.40

III.2.1.2. Collecte des données

Une fois les entrées pertinentes du modèle sont sélectionnées, l'objectif de cette étape est de les recueillir. La base de données ainsi constituée doit répondre à deux exigences **(Dreyfus *et al*2002)**

• Contenir le maximum d'échantillons ou d'exemples (expérimentaux);

• Etre représentative des données susceptibles d'intervenir en phase d'utilisation du modèle neuronal.

Le tableau III.3 récapitule l'ensemble de données d'entrée utilisé dans le développement du modèle neuronale pour différents composés.

Tableau III.3. Liste des données d'entrée utilisée dans cette étude (Poling *et al*. 2001 ; Kestin *et al* 1971). (https://www.chemeo.com/)

Numéro	*Composé*	*Tc(K)*	*Pc (bar)*	*M (g/mol)*	*T©*	*η (cP)*
1	**Pyrrole**	**467,00**	**66,20**	**94,94**	**0,00**	**0,40**
2	**2,2-Dimethylpentane**	**465,10**	**35,51**	**70,13**	**0,00**	**0,24**
3	**Isobutane**	**282,50**	**50,60**	**28,05**	**0,00**	**0,01**
. .						
100	**Isooctane**	**617,45**	**31,91**	**106,17**	**20,00**	**0,81**
101	**Methyl propyl ketone**	**789,55**	**26,78**	**194,23**	**20,00**	**2,71**
102	**valeric acid**	**781,17**	**35,09**	**164,20**	**20,00**	**9,22**
. .						
156	**Phytadiene**	**781,19**	**35,09**	**164,20**	**20,00**	**9,22**
157	**1,2-dichloro ethane**	**730,98**	**37,66**	**137,18**	**20,00**	**6,08**
159	**Ethyl valerate**	**565,20**	**37,13**	**102,13**	**20,00**	**0,69**
160	**Isobutyl iodide**	**833,23**	**63,49**	**138,12**	**20,00**	**2,71**
. .						
327	**propylene glycol**	**667,15**	**23,81**	**107,15**	**40,00**	**0,42**
328	**ethylen glycol**	**708,00**	**14,79**	**212,46**	**40,00**	**7,00**

III.2.1.3.Division de la base de données

La base de données utilisée dans ce travail est répartie en :

1. 328 points expérimentaux pour l'optimisation de l'architecture de RNA

Les 328 points expérimentaux utilisé pour l'optimisation de l'architecture de RNA ont été divisée en trois sous-ensembles : la base d'apprentissage , la base de test , et la base de validation selon la division suivante :60%-20%-20% , 70%-15%-15% , 80%-10%-10%.

III.2.1.4. Optimisation des architectures des RNA

L'optimisation des architectures des RNA de type perceptron multicouche (PMC), à été faite par le logiciel «STATISTICA» via les étapes suivantes :

- L'algorithme Quasi Newton à propagation en arrière (*Quasi Newton back propagation algorithm*, plus précisément : *Broyden-Fletcher-Goldfarb-Shannoalgorithm**BFGS***) a été employée comme algorithme d'apprentissage **.**
- Cinq fonctions d'activations différentes sont utilisées pour la couche cachée et la couche de sortie (**Figure III.3**).
- La somme des carrés (*Sum of Squares **SOS***) a été choisie en tant que fonction d'erreur.
- Le nombre de neurones dans la couche cachée a été varié de 2 à 20 neurones.

Quatre itérations (2000, 4000, 5000 et 6000) ont été utilisées pour l'exécution de chaque division.

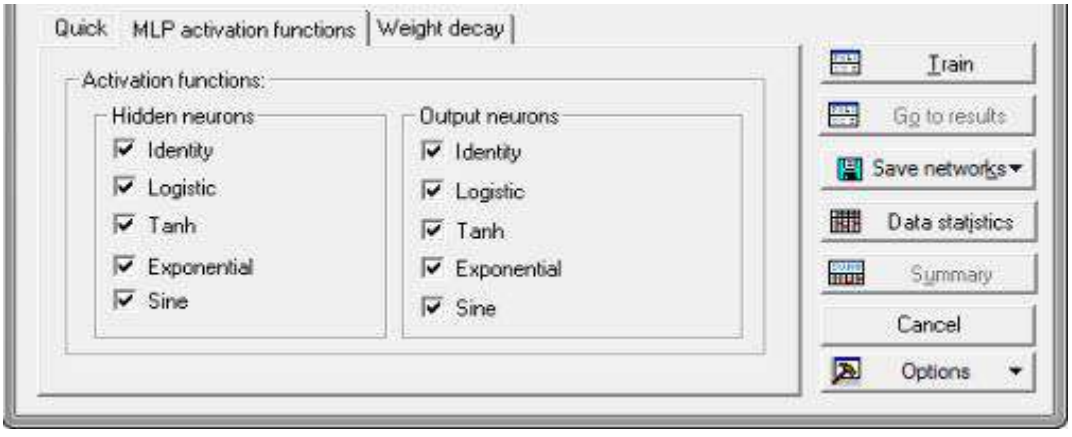


Figure III.1. Capture d'écran pour le choix des fonctions d'activation sur STATISTICA

III.2.1.5. Choix du meilleur modèle

Le choix du meilleur modèle est basé sur deux critères : l'erreur de somme des carrés *(SOS)* et le coefficient de régression *(R)*. Ce choix s'effectue selon la règle test et erreur tel que *SOS* plus proche de 0 et *R* tant vers 1.Les paramètres de la régression linéaire sont obtenus en utilisant la fonction MATLAB "*postreg*".Le pouvoir de prédiction d'un tel modèle peut être estimé par le coefficient de corrélation *R* calculé selon l'équation III.04, une valeur de *R* supérieure à 0,5 est généralement considérée comme satisfaisante, une valeur supérieure à 0 ,9 est excellente.

III.2.1.6. Performances du meilleur modèle développée

La performance et la précision du meilleur modèle neuronale obtenu dans cette étude, a été évaluée par quatre types d'erreurs : la racine d'erreur quadratique moyenne*(REQM)*, l'erreur standard de prédiction*(ESP)* et l'erreur relative moyenne *(ERM).* Les performances des régressions ont été aussi testées à l'aide des coefficients de régression *(R)* et de détermination *(R^2)*, en plus des vecteurs de régression : les valeurs de la pente *(α)*, et de l'interception *(β)*. Ceci est fait sur l'ensemble des données d'apprentissage, de test, de validation et sur la base totale.

Les définitions mathématiques des quatre types d'erreurs, du coefficient de régression *(R)* et du coefficient de détermination *(R^2)* sont données par les équations **(III.1–III.5)**, respectivement :

$$\boldsymbol{REQM = \sqrt{\sum_{i=1}^{N}\left(y_i^{exp} - y_i^{cal}\right)^2 / N}} \qquad \textbf{(III.1)}$$

$$\boldsymbol{ESP = \left(REQM / \hat{y}^{exp}\right) * 100} \qquad \textbf{(III.2)}$$

$$\boldsymbol{ERM = (100/N) * \sum_{i=}^{N} |(y_i^{exp} - y_i^{cal})| / y_i^{cal}} \qquad \textbf{(III. 3)}$$

$$\boldsymbol{R = \frac{\sum_{i}^{N}[(y_i^{exp} - \hat{y}^{exp})(y_i^{cal} - \hat{y}^{cal})]}{\sqrt{\sum_{i=1}^{N}\left(y_i^{exp} - \hat{y}^{exp}\right)^2}\sqrt{\sum_{i=1}^{N}\left(y_i^{cal} - \hat{y}^{cal}\right)^2}}} \qquad \textbf{(III.4)}$$

$$R^2 = 1 - \sum_{i=1}^{N} \left(y_i^{exp} - y_i^{cal}\right)^2 \Big/ \sum_{i=1}^{N} \left(y_i^{exp} - \hat{y}^{exp}\right)^2 \qquad (\mathbf{III.5})$$

Avec : $\hat{y}^{exp} = \sum_{i=1}^{N} y_i^{exp} / N$

Où N est le nombre des données pour chaque phase : (apprentissage, test, validation ou base totale), y^{cal} est la valeur calculée (prédite), y^{exp} est la valeur expérimentale et $\hat{y}^{exp}$ la moyenne des valeurs expérimentales.

III.2.1.7. Analyse de sensibilité par la méthode de poids

L'analyse de sensibilité est un outil important pour l'évaluation des modèles mathématiques. Elle est utilisée pour diverses raisons, notamment la validation du modèle, l'évaluation du comportement des différentes variables du modèle, et la confirmation du choix des variables du modèle via la détermination des contributions de chaque variable choisie sur le modèle. De ce fait, il est donc important d'utiliser cette analyse sur le modèle de type PMC-RNA.

Dans cette étude l'analyse de sensibilité par la méthode de "Poids" (*Weights method*) a été utilisée, afin d'évaluer l'impact de la contribution de toute variable d'entrée ($T, Pc, M\ et\ T$) sur la viscosité (η).

Cette méthode, proposée d'abord parGarsonet reprise parGoh, donne une quantification de l'importance relative (*Ir*) des différentes entrées sur la sortie du RN. Elle se base sur le partitionnement des poids des connexions en :

- Poids de connexion entrée –cachée (w_{ji}^{I}) ;
- Poids de connexion cachée- sortie (w_{1j}^{H}).

Le processus de calcul, qui se compose de quatre étapes, est schématisé sur l'organigramme de la figure III.4.

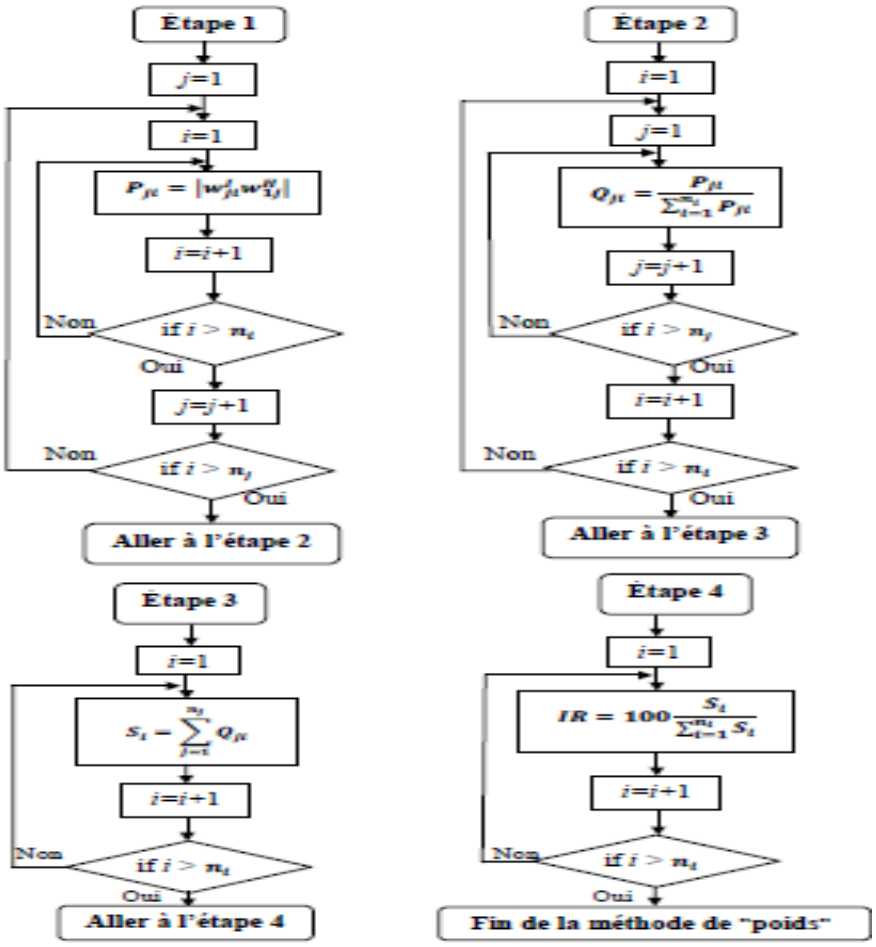


Figure III.2. Organigramme illustrant l'analyse de sensibilité par la méthode de la partition des poids (méthode de poids).
(khaoune.2013)

Comme nous avons mentionné précédemment dans le paragraphe III.2.1.7, nous avons utilisé la méthode de poids, pour déterminer la contribution des paramètres d'entrée sur l'IR (voir figure III.2).

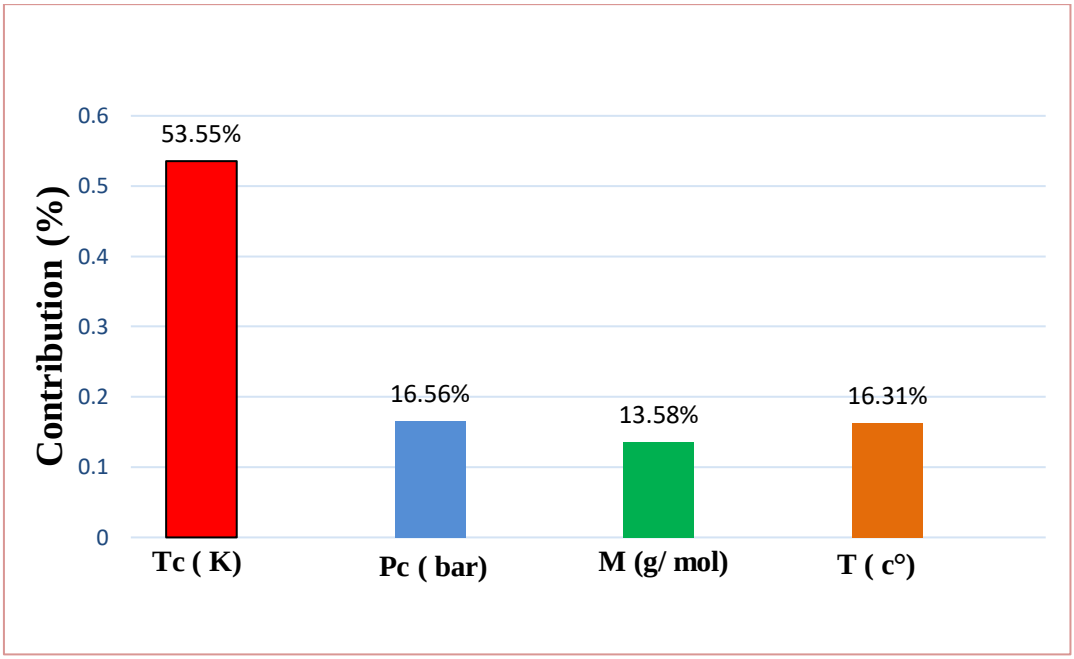


Figure III.3. Contributions relatives des paramètres optiques d'entrée pour le modèle de PMC-RNA de l'indice de réfraction IR.

A partir les résultats de l'analyse de sensibilité qui sont traduit par l'importance relative **(*IR*)** de chaque paramètre présenté dans la figure précédente qui sont : 53,55% pour l'entrée de Tc, 16,56% pour l'entrée de Pc , 13,58% pour l'entrée de M et 16,31% pour l'entrée de T .

Il convient de noter que la température critique a une forte réflexion par rapport aux autres entrées sur la sortie (η) avec un pourcentage égal 53,55%.

III.3. Résultats et discussions

III.3.1. Architectures des modèles neuronaux obtenus Les résultats de l'optimisation des architectures des RNA utilisées pour chaque division sont résumés dans le tableau suivant

Tableau III.4. Les résultats de l'optimisation des architectures des RNA

Division	Itération	RN Optimale	SOS	R	Fct de T CC	Fct de T CS
60_20_20	2000	4-[19]-1	App=1,27	0,8155	Tanh	Log
			Tes=1,26	0,7571		
			Val=0,643	0,8419		
	4000	4 [13]-1	App=1,27	0,8143	Tanh	Exp
			Tes=1,26	0,7546		
			Val=0,608	0,8480		
	5000	4-[18]-1	App=2,51	0,8021	Tanh	Log
			Tes=1,19	0,8842		
			Val=1,62	0,7362		
	6000	4-[17]-1	App=1,24	0,8198	Tanh	Exp
			Tes=1,19	0,7802		
			Val=0,517	0,8873		
70_15_15	2000	4-[4]-1	App=1,22	0,8151	Log	Log
			Tes=1,09	0,7866		
			Val=0,602	0,8054		
	4000	4-[6]-1	App=1,17	0,8225	Tanh	Exp
			Tes=0,952	0,8317		
			Val=0,786	0,8723		
	5000	4-[11] -1	App=1,26	0,8084	Tanh	Exp
			Tes=1,21	0,7515		
			Val=0,613	0,8243		
	6000	4-[4] -1	App=1,24	0,8109	Log	Log
			Tes=1,11	0,7816		
			Val=0,632	0,8014		
80_10_10	2000	4-[12]-1	App=1,24	0,8155	Log	Log
			Tes=0,653	0,8202		
			Val=0,462	0,8419		
	4000	4-[18]-1	App=1,19	0,8128	Log	Log
			Tes=0,599	0,8307		
			Val=0,276	0,9392		
	5000	4-[17] -1	App=1,20	0,8114	Log	Log
			Tes=0,509	0,8465		
			Val=0,262	0,9445		
	6000	4-[11]-1	App=1,20	0,8630	Log	Log
			Tes=0,480	0,8630		
			Val=1,20	0,9401		

D'après le tableau la meilleure architecture de RNA est (4-17-1) pour la division 80%-10%-10% , (voir la figure III.3)

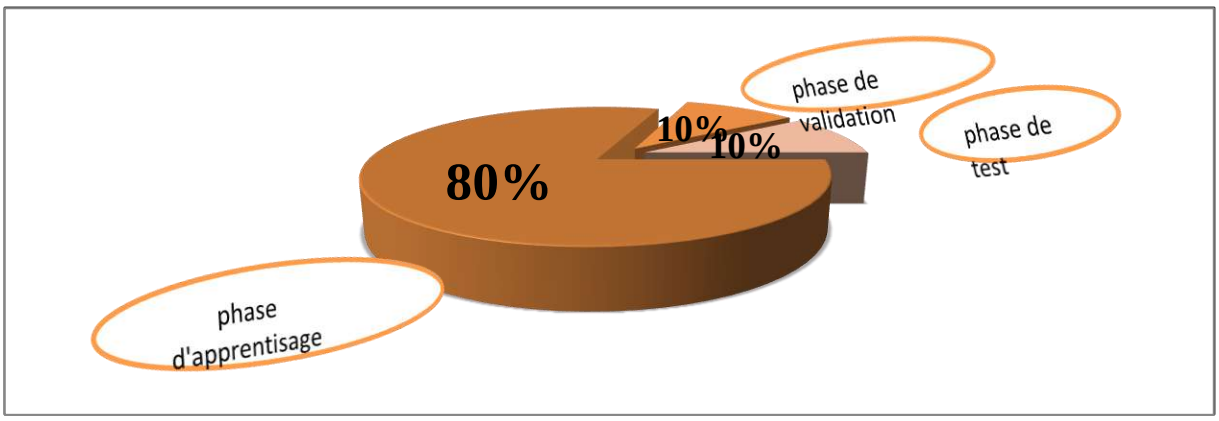


Figure III.3. Représentation graphique du la meilleur division de la base des données.

Les modèles neuronaux conçues et optimisés possèdent des valeurs de *SOS* relativement acceptables pour le paramètre de la viscosité, pour les trois sous-ensembles (apprentissage, test et validation). Les valeurs des coefficients de régression R des modèles neuronaux conçues et optimisés sont proche de l'unité monteront ainsi la grande performance de la méthodologie neuronale développé dans cette étude.

Tableau III.5. Architecture du meilleur modèle obtenu.

Couches	**Nombre de neurones**	**Fonctions d'activation**	**Valeurs de *R* et *SOS***	
			R^{App}	0,820434
Couche d'entrée	4	***(Aucune)***	R^{Tes}	0,846525
Couche cachée	17	Log	R^{Val}	0,944591
Couche de sortie	1	Log	SOS^{App}	1,20
Algorithme d'*App*	BFGS 106		SOS^{Tes}	0,509
Fonction d'erreur	Somme Des Carrés (*SOS*)		SOS^{Val}	0,262

III.3.2. Expressions mathématiques du meilleur modèle neuronale obtenu

À partir du RNS optimisé et qui est représenté sur la figure III.4, on peut exprimer l'assimilation du substrat par un modèle mathématique qui y incorpore toutes les entrées E_i $(T, M, Pc\ et\ T)$ comme suit:

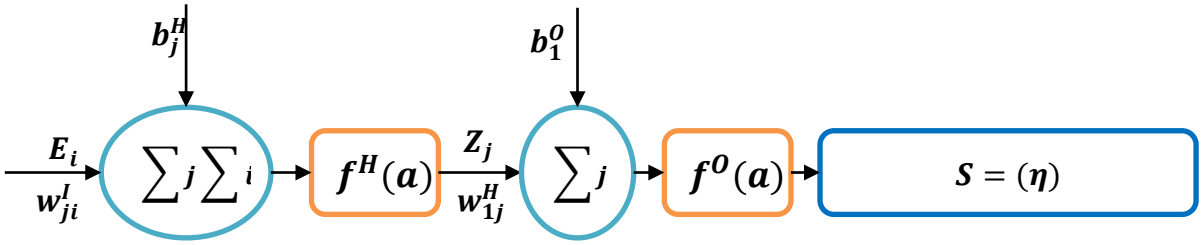


Figure III.4. Représentation schématique d'un réseau du modèle de type PMC-RNA.

Les expressions mathématiques des sorties (Z_j)de la couche cachée et (S) de la couche de sortie de chaque paramètre sont données par les équations ci-après **(III.10–III.11)** :

$$Z_j = f^H\left[\sum_{i=1}^{4} w_{ji}^I E_i + b_j^H\right] = \frac{1}{1 + \sum_{i=1}^{4} w_{ji}^I E_i + b_j^H} \qquad \textbf{(III. 7)}$$

$$S = f^O\left[\sum_{j=1}^{17} w_{1j}^H Z_j + b_1^O\right] = \frac{1}{1+\frac{1}{1+\sum_{i=1}^{4} w_{ji}^I E_i + b_j^H}} \qquad \textbf{(III.8)}$$

Ou w_{ji}^Ireprésente le poids synaptique de la connexion du neurone *i*de la couche d'entrée au neurone *j* de la couche cachée ; w_{1j}^Hreprésente le poids synaptique de la connexion du neurone *j* de la couche cachée au neurone de la couche de sortie ;b_j^H etb_1^O représentent les biais du neurone *j*de la couche cachée et la couche de sortie respectivement. La matrice de poids et biais, de RN optimisé, sont donnés dans les tableaux III.7.

Tableau III.6. Poids et biais du RN optimal.

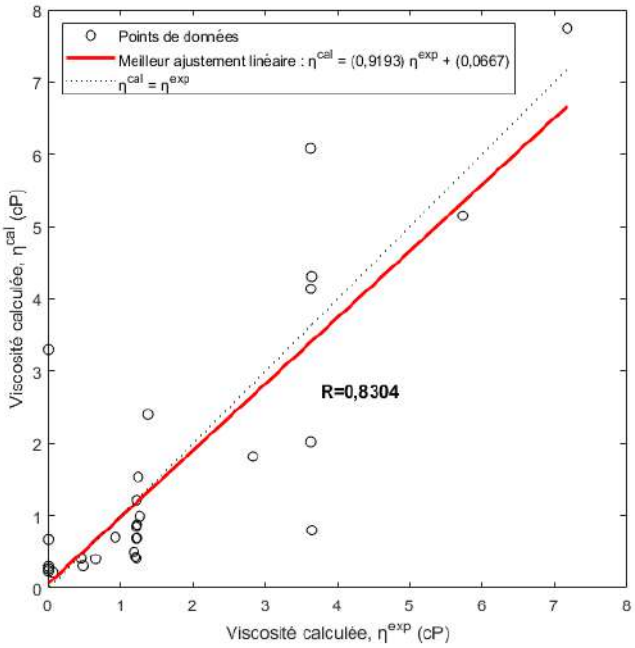
	Connexions Couche d'entrée-Couche cachée				**Connexions Couche cachée-Couche de sortie**	
Poids				**Biais**	**Poids**	**Biais**
w_{j1}^{I}	w_{j2}^{I}	w_{j3}^{I}	w_{j4}^{I}	b_{j}^{H}	w_{1j}^{H}	b_{1}^{0}
-70,82	24,11	-27,85	-26,67	2,87	-13,67	
-38,26	-31,59	-9,94	36,15	93,46	-9,62	
-84,76	11,35	6,80	-7,01	8,84	-36,52	
-71,63	36,07	-30,97	-31,10	-11,06	-14,53	
-66,77	-17,96	-12,36	7,01	69,28	11,99	
-75,47	6,45	-5,73	-12,76	17,26	-26,16	
-78,72	9,54	-10,91	-11,75	15,42	-24,36	
-70,21	13,36	-24,01	-20,07	28,68	-15,64	
-74,38	17,16	-19,82	5,79	63,85	-1,16	139,55
-64,26	44,64	-21,14	-27,09	-25,82	-22,48	
-71,95	-8,82	-19,50	5,75	47,10	-1,24	
-68,05	34,60	-38,70	-31,50	-9,78	-4,13	
-71,30	10,32	-17,18	-20,05	26,91	-21,33	
-51,08	0,11	-4,67	13,62	7,58	-33,58	
-36,47	-27,32	-11,64	27,45	105,03	-12,72	
-96,37	-43,63	-20,86	-19,59	22,00	-0,56	
43,67	-125,74	-68,04	-145,08	191,53	-129,51	

III.3.3. Estimation de la performance du meilleur modèle neuronale

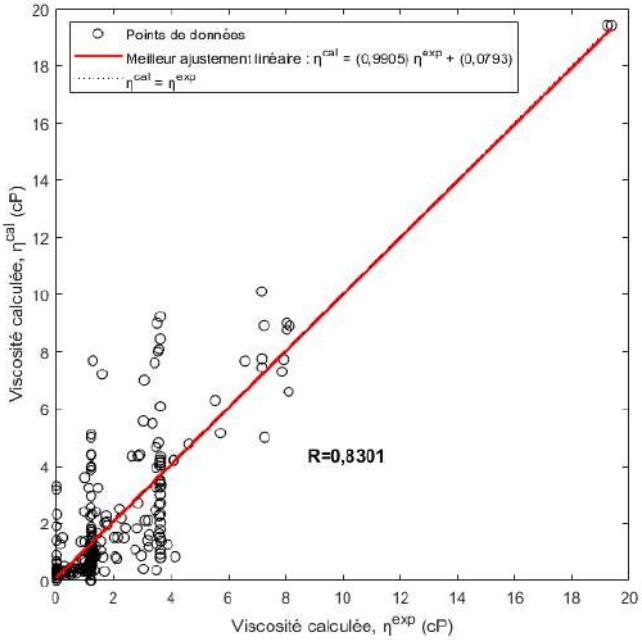
III.3.3.1. Comparaison graphique entre les valeurs expérimentales et calculées

La comparaison entre les valeurs de la viscosité expérimentales et celle calculées par le meilleur modèle neuronale obtenu est illustrées sur la figure**(III.8)**

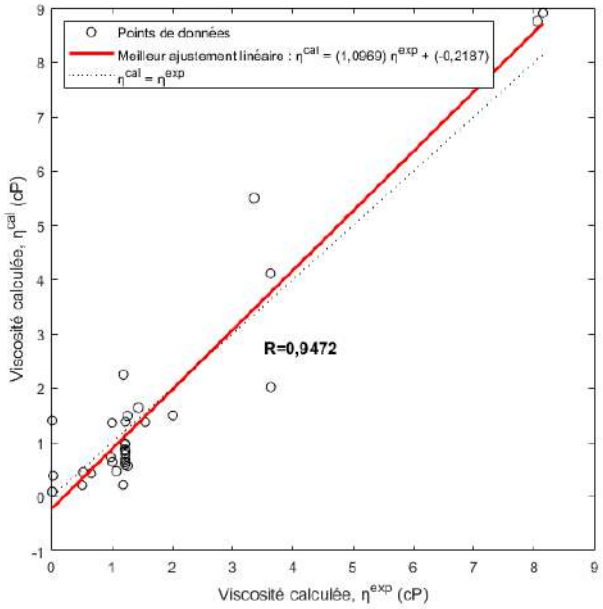
(a)


Points de données
Meilleur ajustement linéaire : η^cal = (0,9193) η^exp + (0,0667)
η^cal = η^exp
R=0,8304
Viscosité calculée, η^cal (cP)
Viscosité calculée, η^exp (cP)

(b)


Points de données
Meilleur ajustement linéaire : η^cal = (0,9905) η^exp + (0,0793)
η^cal = η^exp
R=0,8301
Viscosité calculée, η^cal (cP)
Viscosité calculée, η^exp (cP)

(c)



(d)

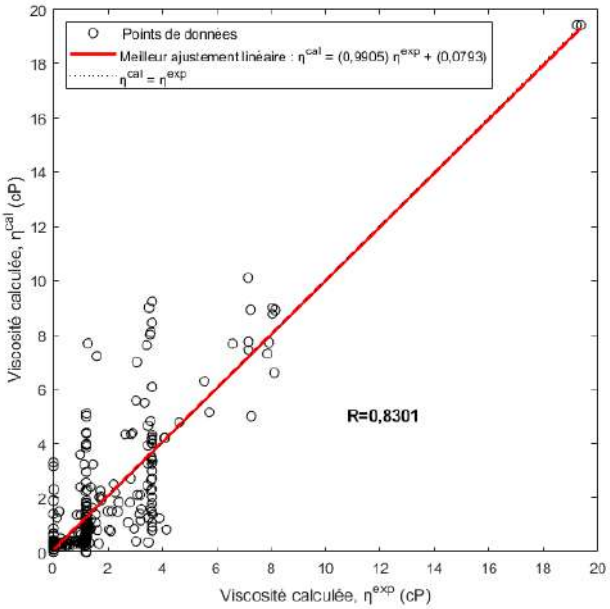


Figure III.5. Comparaison entre les valeurs de la viscosité expérimentales et celle calculées :**(a)**base de test, **(b)** base d'apprentissage, **(c)**base de validation, **(d)** base totale

Le tableau III.7 rassemble les vecteurs de régression linéaire du meilleur modèle neuronale qui donne des résultats satisfaisants avec des valeurs des vecteurs de régression approchant l'idéal [i.e. α=1 (pente), β=0 (y intercepter), R=1 (coefficient de corrélation)]

Tableau III.7. Vecteurs de régression linéaire issue de l'équation linéaire : $y^{cal} = \alpha y^{exp} + \beta$, [$\alpha$ (pente), β (ordonnée à l'origine), R (coefficient de corrélation)].

Fig	La pente (m)	L'intercepter (p)	R
All	0,9905	0,0793	0,8301
Train	0,9905	0,0793	0,8301
Test	0,9193	0,0667	0,8304
Validation	1,0969	-0,2187	0,9472

III.3.3.2 Performance du meilleur modèle neuronale obtenu

La performance du meilleur modèle neuronale obtenu, en termes de la racine d'erreur quadratique moyenne (*REQM*) et l'erreur standard de prédiction (ESP), est illustrée dans le **tableau III.8**.

Tableau III.8. Performance du meilleur modèle neuronale obtenu.

Paramètres Statistiques	R^2	*(REQM)*	*(ESP)*	*(ERM)*	*N*
Phase d'apprentissage					
IR^{App}	0,6890	1.5804	67.1920	5.826110^{-3}	264
Phase de test					
IR^{Test}	0,6895	1.0534	65.4919	1.233910^{-4}	32
Phase de validation					
IR^{Val}	0,8972	1.0534	43.1910	3.725710^{-3}	32
Phase entière (apprentissage + test + validation)					
IR^{Ent}	0,6890	0.7136	74.8950	4.6810^{-3}	328

Selon les résultats de différents coefficients statistiques et types d'erreur présentés dans le **tableau III.8**, le modèle développé était très intéressant, comme montrent les valeurs de R^2 qui sont supérieures à **0,68** pour ce modèle et dans toutes les sous bases des données possible.

Les valeurs de REQM calculées ont aussi confirmé que notre modèle est très précis car ils ont des valeurs compris entre (0,7136 – 1,5804), ceci est pour les quatre phases des sous-ensembles possibles

III.4 Comparaison avec un travaille précédent

La comparaison est illustrée dans le tableau suivant

Paramètres Statistiques	***R***	***(REQM)***	**Bourekba(Tc,Pc,Vc)**	
			R	***(REQM)***
		Phase d'apprentissage		
IR^{App}	**0,8301**	**1.5804**	**0.9968**	**0.0583**
		Phase de test		
IR^{Test}	**0,8304**	**1.0534**	**0.9972**	**1.518**
		Phase de validation		
IR^{Val}	**0,9472**	**1.0534**	**0.9938**	**0.2976**

On a fait cette comparaison selon le coefficient de régression(R) et la racine d'erreur quadratique moyenne (REQM) , dans la base des donnés on a prendre 328 point expérimentaux par rapport la base des donnés de Bourakba qu'elle prendre 150 pointe expérimentaux .

III.4.Conclusion

Dans ce chapitre nous avons abordé le problème de prédiction de la viscosité des liquides, en utilisant le toolbox de RN en MATLAB.

on a discuté l'ensemble des résultats obtenus par le modèle de type PMC-RNA développé, afin de prédire la viscosité .Nous avons discuté plusieurs résultats, telles que :les architectures et les résultats première des meilleures modèles obtenus, la validation de modèle finaux de type PMC-RNA. Puis l'estimation des erreurs et le calcul des coefficients statistiques pour le modèle comme le calcul des REQM, ESP et ERM, l'analyse de la sensibilité des paramètres d'entrée sur la sortie

L'analyse de sensibilité nous a permis de connaître les entrées qui ont une influence sur la viscosité. Par l'utilisation de la méthode de poids de connexion on a trouvé que toute les paramètres sont influencent (la température critique, la masse moléculaire, la température, la pression critique).

Conclusion générale

et perspectives

L'objectif de cette mémoire est d'utiliser la modélisation comme approche pour estimation la viscosité des liquides.

Notre première contribution a porté sur l'utilisation des réseaux de neurones artificiels (de type perceptron multicouches).Le développement de cette approche après élaboration d'un programme sur MATLAB a été fondé sur deux étapes. En premier, niveau conceptuel qui comportera la préparation de la base de données et l'optimisation pour trouver l'architecture du réseau de neurones statique optimal (RNSO). En second, niveau de la mise en œuvre de l'architecture obtenue, dans le but est le test de généralisation et d'interpolation du réseau de neurones optimisé. Le RNSO obtenu durant cette contribution est :

- {4-[17]-1} pour les liquides : {4 neurones dans la couche d'entrée, 17 neurones dans la couche cachée, neurone dans la couche de sortie} avec R =0,8301.

Notre deuxième contribution a porté sur l'étude comparative entre les modèles neuronaux optimisés et les modèles théoriques : Przezdziecki et Sridhar pour le calcul de la viscosité des liquides. Les résultats obtenus lors de cette contribution montrent que les réseaux de neurones sont des outils parfaitement fiables et performants pour la prédiction de viscosité.

Les conclusions à retenir lors de cette étude, sont :

- Les réseaux de neurones fonctionnent comme une boite noire et les paramètres du réseau (poids et biais) n'ont pas de signification physique;

- L'application des réseaux neuronaux ne développe pas directement la théorie de description du système, mais rend faisable la modélisation et la simulation;

- La modélisation par les réseaux de neurones est une méthode qui est basée seulement sur des données expérimentales et/ou semi expérimentale, donc la qualité et la quantité des données décident de l'exactitude et la robustesse du modèle
- Les réseaux de neurones sont des outils statiques, qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points comme toute méthode statique.
- Toute en estimant avoir atteint les objectifs tracé pour cette étude, nous envisageons en respectives
    a) D'élargir la base de données relative à la viscosité

b) De modéliser d'autres propriétés comme la viscosité
c) D'utiliser d'autre techniques de modélisation tel que support vector machine, QSPR, neuro-fuzzy...

En perspective, tout en estimant avoir atteint notre objectif tracé pour cette étude, il serait souhaitable d'essayer de concevoir un seul modèle neuronal, à deux sorties, capable de calculer à la fois la viscosité des liquide à n'importe quelle température et à n'importe quelle pression.

Références bibliographiques

Addil EL Akkad, 1993. Etude comparative des perturbations de la couche limite et de la portance, sur plaque plane et sur modèle d'aile en présence de fluides désirants. Exigence partielle pour l'obtention de garde de maitre en science appliquées. Université du Québec a 2Chicoutimi. P46-50.

Alp Mestan, Introduction aux Réseaux de Neurones Artificiels Feed Forward,

Aymen Messaâdi, **(2011)**. Etude des modèles de corrélation de volume et de viscosité dans les systèmes binaires liquides.

Basheer, I. A., Hajmeer,M (2000). Artificial neural networks : fundamentals computing , design ,and application . Journal of microbiological methods , 43(1),3-31.

Barka Amel, 2016. Evaluation des indices de nature physico-chimique de quelques huiles alimentaires de friture et impact sur la santé du consommateur. Mémoire de Master en Science Alimentaires. Université de Tlemcen. P 9.

Bellet R. Non-newtonien flows 541 D. Gaudu Institut de mécanique des fluides Toulouse.

Bertrand Joël ,**1983**.Agitation de fluides visqueux cas de mobile à pales, d'encres et de barrières'' thèse docteur es sciences physiques d'etat : génie chimique toulouse, inp.

Bishop, C. M. (1995). Neural networks for pattern recognition. Oxford university press.

Bitam, S, (2018)."Modélisation de l'activité thérapeutique à partir de la structure moléculaire". Thèse de Doctorat en génie des procédés, Laboratoire de Biomatériaux et Phénomènes de Transport (LBMPT), Département de génie des procédés et environnement, Université Yahia Fares de Médéa. Médéa, Algérie.

Briant J., Denis J., Parc G,**1985.** Propriétés rhéologiques des lubrifiants'' Edition Technip, Paris et institut francais du pétrole. Rueil-Malmaison ISBN 2.7 108.0435-2.

Bourekba , 2013.modélisation neuronale de la viscosité des liquides te des gaz , thèse de master en génie des procédés, Université de MEDEA YAHIA FARES.

Bougroura Alla Eddine, 2006. Réalisation d'un module de calcule en MDF. Mémoire de fin d'étude présentation obtenir le diplôme d'ingénieur d'états. Université de Batna.

Calchera Gilles. (1999). Viscosité des liquides : définition de la viscosité , influence de la température, mesure de la viscosité , application aux huiles de graissage Paris : CNAM ,29p. Mémoire Examen probatoire : Instrumentation mesure. Contrôle industriel : Conservatoire national des arts e matières.

Camillo Colgi, **11, décembre 1906.** The neuron doctrine - theory and facts Nobel Lecture December, Pages 189–217.

Claude Touzet, 1992.Les réseaux de neurones artificiels, introduction au connexionnisme : cours, exercices et travaux pratiques. ec2, Collection de l'EERIE, N. Giambiasi. Ffhal-01338010.

Dabir S. Viswanath University of Missouri, Columbia, **TUSHAR K. GHOSHMO**, U.S.A. University of Missouri, Columbia, **MO, U.S.A. DASIKA H. L. PRASAD** Indian Institute of Chemical Technology, Hyderabad, India **NIDAMARTY V. K. DUTT** Indian Institute of Chemical Technology, Hyderabad, India and **KALIPATNAPU Y. RANI** Indian Institute of Chemical Technology, Hyderabad, India**.** Viscosity of Liquids Theory, Estimation, Experiment, and Data.

Darwiche Ahmed, 2012. Microrhemtre sur puce pour l'étude de l'écoulement d'un liquide de proche d'une surface solide. Thèse doctorat en Laser, Matiére et Namosciences. Université Bordeaux. Ecole doctorale de science physiques et d l'ingénieur. P16.

Davalo, E., Naïm, P., & Clément, F. M. (1989). Des réseaux de neurones. Paris: Eyrolles.

Dreyfus, G., J-M. Martinez, M. Samuelides, M.B. Gordon, F. Badran, and S.

Gana Masiine, 2016, Implémentation d'un réseau de neurones dans un microcontrôleur, mémoire de fin d'étude, université Mouloud Mammeri Tizi Ouzou.

G. Dreyfus, Neural networks: methodology and applications, Springer Science & Business Media, 2005.

Gibouin Florence, (2015).application de méthodes optiques couplées à l'étude d'écoulements de fluides biréfringents. Thèse pour l'obtention du grade de docteur. Université de Poitiers.

Hamadache, (2014) Modélisation en vue de la prédiction ou de la corrélation de l'activité toxicologique à partir de la structure moléculaire. Thèse doctorat. Université de MEDEA.

Hebb, D. O. (1949). The organization of behavior: a neuropsychological theory. J. Wiley; Chapman & Hall.

Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. Proceedings of the national academy of sciences, 79(8), 2554-2558.

Kiyoshi Kawaguchi, 17/06/2000. "The McCulloch-Pitts Model of Neuron", http://wwwold.ece.utep.edu/research/webfuzzy/docs/kk-thesis/kk-thesis-html/node11.html.

Minsky, M., & Papert, S. A. (1988). Perceptrons: An introduction to computational geometry. MIT Press, Massachusetts, USA

Mo Costandi,**Tuesday, August 29, 2006**. The Discovery Of The Neuron, History of Neuroscience, Neuroscience.

Mouas Mohamed, 2012. Etude par dynamique moléculaire de la structure atomique et de la compressibilité isotherme de métaux liquide. Calcule de la diffusion et de la viscosité de

soudures sans plomb par le formalisme de Green.Kubo. Thèse doctorat en Physique de la matiére condensée. Université de Lorrataine. P85.

Moumen Fatima, 2010.étude des effets turbulents de l'écoulement sanguin dans la crosse aortique..Théorie et simulation. Déplome de magister. Université d'Oran es-senia.

Moody, J., & Darken, C. J. (1989). Fast learning in networks of locally-tuned processing units. Neural computation, 1(2), 281-294.

Moussouni Imane, Zaidi Ferial, 2017. Qualité et activité antioxydant de l'huile d'olives

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, 65(6), 386.

Rumelhart, D. E., Hinton, G. E., & McClelland, J. L. (1986). A general framework for parallel distributed processing. Parallel distributed processing: Explorations in the microstructure of cognition, 1(45-76), 26.

Poling B.E., Bransnitz J.M. et O'connell J.P.(2001),"The properties of gases and liquids". 5émé edition, McGREW-HILL, New york, USA.

Si-Moussa, C. (2010)."Modélisation des équilibres de phases à pressions élevées par les réseaux de neurones artificiels". Thèse de doctorat. École nationale supérieure polytechnique. Alger. Algérie

Sordelet, 2018. Les fluides non-newtoniens entre liquide et solide. Concours CGENIAL. Lycée Français de Berlin. P 1.

Talbi M. L. (2011). Analyse et traitement du signal électrocardiographique (ECG). Thèse de Doctorat en science, Spécialité : Electronique, Option : traitement de signal. Université de Constantine. Algérie.

Warren S. Mcculloch, Walter pitts,1943. A logical calculus of the ideas immanent in nervous activity, University of illinois, College of medicine, Department of psychiatry at the illinois neuropsychiatric institute, and the university of Chicago, Bulletin of mathematical biophysics Volume 5.

https://askabiologist.asu.edu/neuron-anatomy Consulté le 15 avril 2021.

WWW.CHEMEO.COM Consulté le 20 avril 2021.

https://www.researchgate.net. Consulté le 5mai 2021.

(www.perso.latribu.com/shagar/steve/pdf/sa3.pdf). Consulté le 28 mars 2021.

https://www.es-france.com/Consulté le 5avril 2021.

https://www.fishersci.fr Consulté le 20 mai 2021.

https://labomat.eu/ Consulté le 20 mai 2021.

https://www.directindustry.fr/ Consulté le 20 mai 2021.