



**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**  
Ministère de l'enseignement supérieur et de la recherche scientifique Université  
Akli Mohand Oulhadj Bouira Faculté Des Sciences Et Science Appliquées  
Département de Génie Mécanique



# **Projet de fin d'étude**

**En vue d'obtention du diplôme master en génie mécanique**

**Option : Génie Mécanique**

**Spécialité : Energétique**

**Modélisation des propriétés thermophysiques et les  
caractéristiques d'écoulement des nanofluides à  
l'aide de l'intelligence artificielle**

**Etudié par :BELKACEMI KHALED**

**DECHOUCHA FAROUK**

**Dirigé par :Mr Mohammed**

**MOUSSAOUI**

**Promotion 2022 / 2023**






## نموذج التصريح الشرفي الخاص بالالتزام بقواعد النزاهة العلمية لإنجاز بحث.

انا الممضي اسفله،

السيد(ة)..... بلقاسم خالص .....الصفة: طالب، استاذ، باحث..... جامعة  
الحامل(ة) لبطاقة التعريف الوطنية:..... 1.007270.82.....والصادرة بتاريخ 2016/04/27  
المسجل(ة) بكلية / معهد..... علوم وتكنولوجيا قسم هندسة ميكانيكية  
والمكلف(ة) بإنجاز اعمال بحث(مذكرة، التخرج، مذكرة ماستر، مذكرة ماجستير، اطروحة دكتوراه).  
عنوانها:..... Modélisation des propriétés thermophysiques et les caractéristiques d'écoulement des nanofluides à l'aide de l'intelligence artificiel  
تحت إشراف الأستاذ(ة):..... موساوي زاهر  
أصرح بشرفي اني ألتزم بمراعاة المعايير العلمية والمنهجية الاخلاقيات المهنية والنزاهة الاكاديمية المطلوبة  
في انجاز البحث المذكور أعلاه.

التاريخ:..... 2023/12/20.....

 توقيع المعني(ة) .

رأي هيئة مراقبة السرقة العلمية:

Turnitin

% 30

النسبة:

الامضاء:.....  
  
قسم الهندسة  
مسالك الهندسة  
البيئية كلف بالتحضير والتدريج بالنيابة  
المعلمة والعلو التكنولوجي طارق

## **Remerciements**

*Je tiens à exprimer ma profonde gratitude envers les personnes qui ont contribué de manière significative à la réalisation de ce mémoire de fin d'études. Le chemin qui m'a conduit jusqu'ici a été long et parsemé de défis, mais grâce au soutien, à l'encouragement et à l'inspiration de nombreuses personnes, j'ai pu accomplir ce travail.*

*Tout d'abord, je tiens à remercier mon directeur de mémoire, M.MOHAMMED MOUSSAOUI, pour sa patience, ses précieux conseils et son expertise. Votre mentorat a été essentiel pour orienter mes recherches et améliorer la qualité de ce mémoire.*

*Mes remerciements vont également à ma famille pour leur soutien indéfectible tout au long de mes études. Votre amour et vos encouragements m'ont donné la force de persévérer.*

*Je tiens à exprimer ma gratitude envers mes amis et camarades de classe, qui ont partagé avec moi les hauts et les bas de ce parcours académique. Votre amitié a rendu cette expérience plus enrichissante. Enfin, je tiens à remercier tous ceux qui ont contribué de près ou de loin à la réalisation de ce mémoire.*

*Merci à tous pour votre précieuse contribution à la réussite de ce projet.*

## resume

Dans cette étude, un perceptron multicouche utilisant l'algorithme de Levenberg-Marquardt pour la propagation en arrière est mis en œuvre à l'aide de nanofluides dans l'environnement MATLAB. Les réseaux de neurones artificiels démontrent leur capacité à modéliser avec une grande précision les variations de conductivité et de viscosité de l'oxyde d'aluminium (Al<sub>2</sub>O<sub>3</sub>) et de l'oxyde de cuivre (CuO) en fonction de paramètres tels que la température, la fraction volumique, la conductivité du fluide de base et la taille des nanoparticules. Cette modélisation repose sur un réseau de neurones composé de deux couches cachées et de 10 à 30 neurones. Le coefficient de régression optimal de 1 obtenu indique une correspondance extrêmement précise entre les valeurs expérimentales et les valeurs prédites par le réseau de neurones, malgré la simplicité de sa structure.

## Abstract

In this study, a multilayer perceptron using the Levenberg-Marquardt algorithm for backpropagation is implemented using nanofluids in the MATLAB environment. Artificial neural networks demonstrate their ability to model conductivity and viscosity variations of aluminum oxide (Al<sub>2</sub>O<sub>3</sub>) and copper oxide (CuO) with high precision, depending on parameters such as temperature, volume fraction, base fluid conductivity, and nanoparticle size. This modeling relies on a neural network composed of two hidden layers and 10 to 30 neurons. The optimal regression coefficient of 1 obtained indicates an extremely accurate correspondence between experimental values and those predicted by the neural network, despite its simple structure.

## ملخص

في هذه الدراسة، تم تنفيذ وحدة تعلم متعددة الطبقات باستخدام خوارزمية Levenberg-Marquardt للانتشار العكسي باستخدام نانوسوائل في بيئة MATLAB. تظهر الشبكات العصبية الاصطناعية قدرتها على نمذجة التغيرات في الكهربية ولزوجة أكسيد الألومنيوم (Al<sub>2</sub>O<sub>3</sub>) وأكسيد النحاس (CuO) بدقة عالية، اعتمادًا على متغيرات مثل درجة الحرارة ونسبة الحجم وتوصيلية السائل الأساسي وحجم الجسيمات النانوية. يعتمد هذا النمذجة على شبكة عصبية تتألف من طبقتين مخفيتين وما بين 10 إلى 30 خلية عصبية. القيمة الأمثل لمعامل التحويل الخطي المتوصل بها وبالغة 1 تشير إلى تطابق دقيق للغاية بين القيم التجريبية وتلك التي تتوقعها الشبكة العصبية، على الرغم من بساطة هيكلها

# Table des matières

Introduction général :.....	11
-----------------------------	----

## *CHAPITRE I*

I.1. Définition : .....	1
I.2. Historique sur les nanofluides:.....	1
I.1. Les nanoparticules et les fluides porteur : .....	2
I.1.1. Taille des nanoparticules : .....	3
I.1.2. Les nanoparticules couramment employées dans la production de nanofluides : .....	4
I.1.3. Types de nanoparticules : .....	4
I.2. Fabrication et préparation des nanofluides :.....	5
I.3. Propriétés thermo physiques des nanofluides : .....	7
I.3.1. la fraction volumique : .....	8
I.3.2. Conductivité thermique (K) : .....	8
I.3.3. Viscosité dynamique ( $\mu$ ) :.....	11
I.3.4. La masse volumique ( $\rho$ ) : .....	13
I.3.5. La chaleur massique (Cp) :.....	13
I.4. Applications des Nanofluides .....	14
I.4.1. Systèmes de réfrigération : .....	14
I.4.2. Systèmes d'énergie solaire : .....	15
I.4.3. Applications électroniques :.....	15
I.4.4. Moteurs à combustion interne : .....	15
I.4.5. Applications de refroidissement industriel : .....	15
I.4.6. Chauffage des bâtiments :.....	15
I.4.7. Refroidissement des systèmes nucléaires : .....	16

I.4.8. Espace et défense :	16
I.4.9. Stockage d'énergie :	16
I.4.10. Applications mécaniques :	16
I.4.11. Activité antibactérienne :	16
I.4.12. Palier magnétique :	16
I.5. Les avantages des nanofluides :	17
I.6. Les inconvénients des nanofluides :	18
I.7. Revue bibliographique	19
conclusion	21
Références	22

## *CHAPITRE II*

introduction	Erreur ! Signet non défini.
II.1. Définition :	26
II.2. Historique sur les Réseaux de neurones	26
II.3. Le neurone biologique	31
II.3.1. Fonctionnement du neurone biologique	32
II.4. Le neurone artificiel	33
II.4.1. fonction d'activation :	35
II.5. L'architecture de réseau de neurones artificiels	38
II.5.1. Réseau de neurone monocouche (Perceptron) :	38
II.5.2. Réseau de neurone multicouche	39
II.6. Apprentissage des RNA	40
II.7. revue bibliographique sur les réseaux de neurones	43
Conclusion	45
Références	47

## *CHAPITRE III*

Introduction :	47
----------------	----

<b>III.1. Matériels et méthodes :</b> .....	<b>48</b>
<b>Outils informatique utilisée :</b> .....	<b>48</b>
<b>III.2. Méthodologie de la modélisation neuronale :</b> .....	<b>49</b>
<b>III.2.1. Collecte la base des données</b> .....	<b>50</b>
<b>III.2.2. Division de la base de données :</b> .....	<b>52</b>
<b>III.3. Optimisation des architectures des RNA :</b> .....	<b>53</b>
<b>III.3.1. Choix du meilleur modèle</b> .....	<b>54</b>
<b>III.3.2. Analyse des erreurs</b> .....	<b>54</b>
<b>III.4. Résultats et discussions</b> .....	<b>55</b>
<b>III.4.1. Architectures des modèles neuronaux obtenus</b> .....	<b>55</b>
<b>III.4.2. Estimation de la performance du meilleur modèle neuronale</b> .....	<b>63</b>
<b>Conclusion</b> .....	<b>69</b>
<b>Conclusion générale :</b> .....	<b>71</b>
<b>Références</b> .....	<b>72</b>



# LIST DES FIGURE

Figure 1 : Les nanoparticules dans un tube. ....	4
Figure 2:Nanotubes de carbone.....	5
Figure 3 :Nanoparticules sphérique.....	5
Figure 4 : One-step method stages for preparing nanofluids [6]. ....	6
Figure 5 : Two-step method stages for preparing nanofluids [6,7].....	7
Figure 6 :La relation entre le Machine Learning et les réseaux de neurones .....	26
Figure 7: Le neurone biologique (œuvre d'artiste).....	32
Figure 8: la composition d'un neurone artificiel.....	35
Figure 9 : (a) Fonctions d'activations « seuil » ; (b) Fonctions d'activations « linéaire », (c) Fonctions d'activations « sigmoïde ». ....	36
Figure 10: Exemple d'un réseau de neurones. ....	39
Figure 11: Schéma d'un perceptron Multicouche .....	40
Figure 12 : La méthodologie employée pour la modélisation neuronale .....	50
Figure 13 : les fonctions d'activation utiliserles fonctions d'activation utiliser .....	54
Figure 14 : Graphique représentant la meilleure division de la base de données. .	63
Figure 15 : Comparaison entre les valeurs expérimentales et celle calculées a Base global : (a) Al <sub>2</sub> O <sub>3</sub> viscosité , (b) Al <sub>2</sub> O <sub>3</sub> conductivité, (c) CuOviscosité , (d) CuO conductivité .....	64
Figure 16 : valeurs calculer et les valeurs experimantales de viscosité de CuO on fonction de (a) Taille (b) Fraction volumique (c) Température (d) fluide de base	65
Figure 17 : valeurs calculer et les valeurs experimantales de conductivité de CuO on fonction de (a) Température (b)Taille (c) Fraction volumique (d) fluide de base .....	66
Figure 18 : valeurs calculer et les valeurs experimantales de viscosité de Al <sub>2</sub> O <sub>3</sub> on fonction de (a)Taille (b)Fraction volumique(c)Température(d) fluide de base .....	67
Figure 19 : valeurs calculer et les valeurs experimantales de conductivité de Al <sub>2</sub> O <sub>3</sub> on fonction de (a) Taille (b)Température(c) Fraction volumique (d) fluide de base.....	68

## **LISTE DES TABLEAUX**

<b>Tableau 1: Différentes fonctions d'activations utilisées dans les RNA .....</b>	<b>37</b>
<b>Tableau 2 : Logiciels utilisés .....</b>	<b>48</b>
<b>Tableau 3: Énumération des paramètres des entrées et des sorties.....</b>	<b>51</b>
<b>Tableau 4 : documentation des données expérimentales .....</b>	<b>52</b>
<b>Tableau 5 : détaillées des données expérimentales .....</b>	<b>52</b>
<b>Tableau 7 : Les résultats de l'optimisation des architectures des RNA pour la viscosité .....</b>	<b>55</b>
<b>Tableau 8 : Les résultats de l'optimisation des architectures des RNA pour la conductivité.....</b>	<b>58</b>
<b>Tableau 9 : Architecture du meilleur modèle obtenu.....</b>	<b>61</b>

## **Introduction général :**

L'étude des nanofluides, ces suspensions de nanoparticules dans un liquide de base, constitue un domaine de recherche passionnant en constante évolution. Les nanofluides présentent des propriétés thermophysiques exceptionnelles qui en font des matériaux d'un grand intérêt pour de nombreuses applications industrielles et scientifiques. Ce travail est divisé en trois chapitres, chacun abordant des aspects essentiels de la modélisation des propriétés thermophysiques des nanofluides et de leur utilisation dans des domaines variés.

Le premier chapitre introduit le lecteur aux nanofluides en fournissant une définition claire de ces matériaux. Il offre également un aperçu historique de leur développement et explore en détail les caractéristiques des nanoparticules et des fluides de base utilisés pour créer des nanofluides. En outre, ce chapitre examine les méthodes de fabrication et de préparation des nanofluides, tout en se penchant sur les propriétés thermophysiques essentielles telles que la conductivité thermique, la viscosité, la masse volumique et la chaleur massique. Enfin, il explore un large éventail d'applications des nanofluides dans divers domaines, mettant en lumière leurs avantages et leurs inconvénients.

Le deuxième chapitre se consacre aux réseaux de neurones artificiels, une approche d'intelligence artificielle puissante pour la modélisation des nanofluides. Il commence par définir les réseaux de neurones artificiels et explore leur histoire. Ensuite, il compare les neurones biologiques et artificiels, détaillant leur fonctionnement et leur structure. Ce chapitre plonge également dans l'architecture des réseaux de neurones artificiels, notamment les réseaux multicouches, et explique le processus d'apprentissage des RNA. Une revue bibliographique sur l'utilisation des réseaux de neurones dans la modélisation des nanofluides complète ce chapitre.

Le troisième chapitre détaille les matériels et les méthodes utilisés pour mener à bien la modélisation neuronale des propriétés thermophysiques des nanofluides. Il expose la méthodologie de la modélisation neuronale, y compris la collecte et la division des données, ainsi que l'optimisation des architectures des RNA. Les résultats obtenus à partir de cette modélisation sont analysés et discutés en profondeur, mettant en lumière les architectures des modèles neuronaux et leur performance.

Ce travail vise à offrir une compréhension complète de la modélisation des propriétés thermophysiques des nanofluides à l'aide de l'intelligence artificielle, en explorant les bases conceptuelles, les méthodologies, et les résultats obtenus. Il ouvre la voie à de nouvelles

perspectives passionnantes dans la compréhension et l'optimisation de ces matériaux novateurs aux multiples applications.

# ***CHAPITRE I***

## **Chapitre I Généralités sur les nanofluides**

### **I.1. Définition :**

Les nanofluides, une classe de mélanges innovante, suscitent un vif intérêt. Des multiples recherches ont été entreprises afin d'acquérir une meilleure compréhension de leurs propriétés, mais il reste encore des recherches à effectuer afin de définir précisément leurs caractéristiques. Cette partie offre un aperçu des développements dans ce domaine, bien qu'elle ne couvre pas l'ensemble des travaux réalisés. Elle souligne la complexité des propriétés des nanofluides et la diversité des efforts déployés pour en acquérir une compréhension approfondie [1].

Les nanofluides marquent un progrès significatif dans le domaine des mélanges liquides. Ces mélanges révolutionnaires sont constitués de particules nanométriques dispersées dans un liquide, formant ainsi des suspensions colloïdales. Leur potentiel unique a engendré un fort engouement au sein de la communauté scientifique. En effet, les liquides conventionnels utilisés dans les systèmes de refroidissement et de chauffage présentent une conductivité thermique limitée, ce qui restreint leur efficacité dans le transfert de chaleur. Les nanofluides apportent une solution novatrice en intégrant des nanoparticules dotées d'une excellente conductivité thermique dans les liquides de base, améliorant ainsi considérablement les performances thermiques globales et l'efficacité du transfert de chaleur.

Le choix du liquide de base revêt une importance cruciale pour garantir la stabilité de la suspension dans la durée et prévenir les phénomènes d'agrégation. Ce choix dépend de la nature des nanoparticules utilisées. Parmi les solvants les plus couramment employés figurent l'eau, l'éthylène glycol (EG), diverses huiles, le toluène et les fluides de réfrigération.

### **I.2. Historique sur les nanofluides:**

Les nanofluides sont des fluides contenant des nanoparticules dispersées de manière homogène. Ils ont été conçus dans le but d'enrichir les caractéristiques thermiques des liquides traditionnels en ajoutant des nanoparticules à ces derniers. L'idée de base derrière les nanofluides remonte aux années 1990, et depuis lors, ils ont fait l'objet de nombreuses recherches et développements. Voici un aperçu de l'historique des nanofluides :

1. Début des années 1990 : Le concept des nanofluides a été proposé pour la première fois par Choi en 1995. Il a suggéré d'ajouter des nanoparticules à des fluides pour améliorer leurs caractéristiques thermiques, notamment la conductivité thermique et la capacité de transfert de chaleur.

## **Chapitre I Généralités sur les nanofluides**

2. Années 1990-2000 : Les premières recherches sur les nanofluides se sont concentrées sur les nanoparticules métalliques, telles que les nanoparticules d'or et d'argent, du fait de leur conductivité thermique élevée. Les études expérimentales et numériques ont montré des améliorations significatives des propriétés thermiques des nanofluides par rapport aux liquides de base.
3. Années 2000-2010 : Les recherches sur les nanofluides se sont intensifiées et se sont concentrées sur un éventail plus large de nanoparticules, y compris les oxydes métalliques tels que le cuivre oxydé, l'oxyde d'aluminium et l'oxyde de zinc. De plus, les études ont également examiné les impacts des propriétés des nanoparticules, comme la taille, la forme et la concentration, sur les performances des nanofluides.
4. Années 2010-2020 : Les recherches ont continué à se développer dans le domaine des nanofluides, avec un accent accru sur leur application dans divers secteurs industriels, tels que l'électronique, l'énergie solaire, l'automobile et la biotechnologie. De nouvelles techniques de fabrication des nanoparticules et de stabilisation des nanofluides ont également été développées.
5. Depuis 2020 : Les nanofluides continuent de susciter un intérêt croissant en raison de leurs propriétés améliorées. Les recherches se concentrent maintenant sur des domaines tels que l'optimisation des propriétés des nanofluides, les applications spécifiques à certains secteurs industriels et les études sur les impacts environnementaux et la sécurité des nanofluides.

Il convient de noter que bien que les nanofluides aient montré des améliorations prometteuses en termes de transfert de chaleur et de performances thermiques, leur utilisation généralisée dans l'industrie est encore en cours de développement. Des défis subsistent, notamment concernant la stabilité des nanofluides à long terme, les coûts de fabrication et les considérations liées à la sécurité et à l'environnement. Cependant, les nanofluides continuent d'être une zone de recherche active et prometteuse dans le domaine de la science des matériaux et du génie thermique.

### **I.1. Les nanoparticules et les fluides porteur :**

Généralement, les nanoparticules sont de minuscules particules de petite taille dont les dimensions varient entre 1 et 100 nanomètres (nm). Quant aux nanomatériaux, ils se caractérisent par le fait que l'une des trois dimensions est à l'échelle nanométrique, c'est-à-dire

## **Chapitre I Généralités sur les nanofluides**

qu'elle mesure moins de 100 nm. Cependant, il est important de noter que certaines définitions plus larges considèrent comme des nanoparticules celles dont une ou deux dimensions sont inférieures à 100 nm [2].

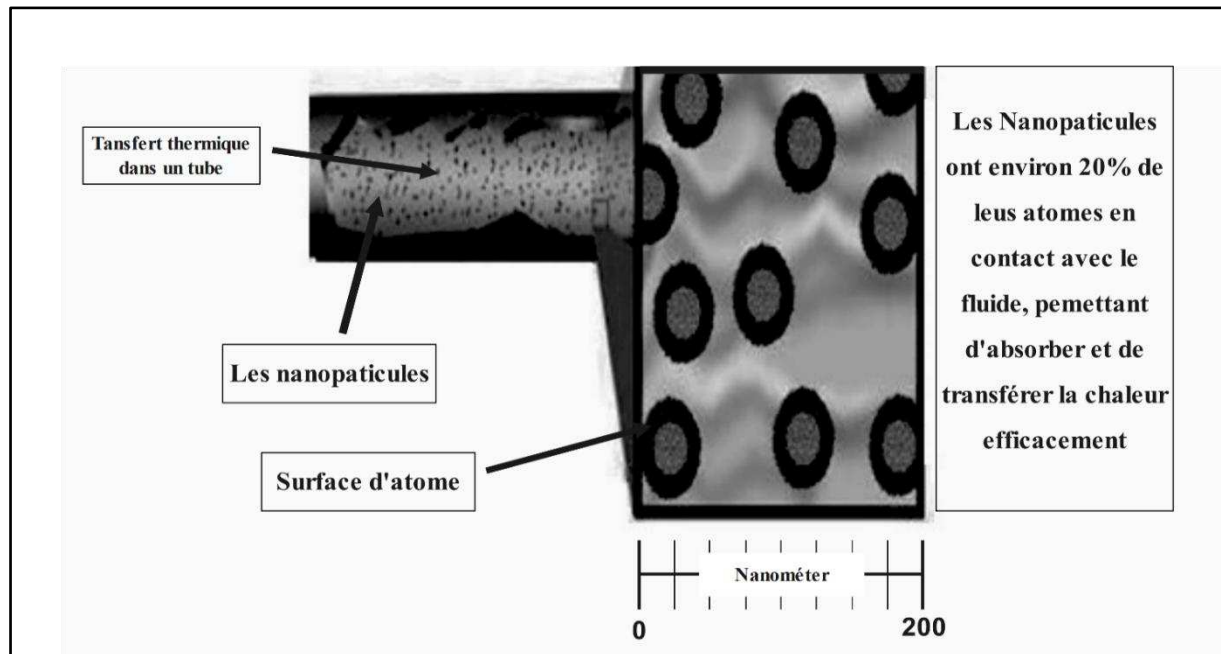
Les nanofluides, d'autre part, résultent de la fusion de nanoparticules avec des liquides de base couramment employés dans des applications impliquant le transfert de chaleur, telles que l'eau, l'éthylène glycol et l'huile moteur, et bien d'autres. Ces nanoparticules peuvent être composées de divers matériaux, notamment des métaux, des oxydes, des carbures, des nitrures ou du carbone. Cette diversité de matériaux offre des opportunités passionnantes pour l'amélioration des performances dans de nombreuses applications industrielles et scientifiques.

### **I.1.1. Taille des nanoparticules :**

La création de nanoparticules est fortement influencée par les processus de fabrication, et ils peuvent être classés en deux catégories principales : les procédés de nature physique et les procédés de nature chimique. Ces deux approches font l'objet de recherches intensives visant à optimiser le coût de production, qui peut parfois être élevé en raison des défis liés à leur mise en œuvre, tout en garantissant la taille souhaitée des particules.

Diverses techniques chimiques et physiques sont à la disposition des chercheurs et des ingénieurs. Pour produire des nanoparticules, une variété de méthodes est utilisée. Ces différentes approches conduisent à l'obtention de nanoparticules sous différentes formes, qu'elles soient libres, enrobées ou enfermées au sein d'une matrice hôte. Bien que la notion d'employer des particules solides en suspension afin d'améliorer les échanges thermiques ait des racines anciennes, remontant notamment aux travaux analytiques de Maxwell datent de 1873 [3], ce n'est qu'à partir des années 1990 que la recherche sur l'utilisation de particules à l'échelle nanométrique a véritablement pris son essor de manière plus approfondie. Cela a été rendu possible grâce au développement de techniques de fabrication spécifiques et innovantes, ouvrant ainsi la voie à de nouvelles opportunités passionnantes dans le domaine de l'ingénierie des nanomatériaux et de l'amélioration des systèmes de transfert thermique.





**Figure 1 : Les nanoparticules dans un tube.**

### **I.1.2. Les nanoparticules couramment employées dans la production de nanofluides :**

Ces particules nanométriques sont regroupées en trois principales catégories en fonction de leur composition :

1. Les nanoparticules d'oxydes métalliques incluent des matériaux tels que l'oxyde d'aluminium ( $\text{Al}_2\text{O}_3$ ), l'oxyde de cuivre ( $\text{CuO}$ ), l'oxyde de silicium ( $\text{SiO}_2$ ) et l'oxyde de titane ( $\text{TiO}_2$ ).
2. Les nanoparticules métalliques comprennent des éléments tels que l'aluminium (Al), le cuivre (Cu), l'or (Au), l'argent (Ag) et le silicium (Si).
3. Les nanoparticules non métalliques englobent des structures comme les nanotubes de carbone (CNT) et le diamant (C).

Cette classification en trois catégories distinctes permet de mieux comprendre la diversité des matériaux nanométriques disponibles, chacun ayant des caractéristiques uniques et des applications spécifiques.

### **I.1.3. Types de nanoparticules :**

La recherche constamment croissante dans le domaine de la création de nouveaux nanomatériaux, tels que les nanoparticules, est à l'avant-garde de l'exploration scientifique. Plus spécifiquement, lorsqu'il s'agit d'applications impliquant le transfert de chaleur, certaines

## **Chapitre I Généralités sur les nanofluides**



nanoparticules se distinguent de manière significative [4]. Parmi ces nanoparticules, nous pouvons mettre en évidence deux catégories:

### **I.1.3.1. Les nanoparticules sphériques :**

Ces minuscules particules ont une forme parfaitement sphérique à l'échelle nanométrique. Elles jouent un rôle central dans les applications associées aux transferts thermiques.

### **I.1.3.2. Les nanotubes :**

Cette catégorie englobe divers types de nanotubes, notamment les nanotubes de carbone (NTC), les nanotubes de titane (TiO<sub>2</sub>), et les nanotubes de silicium. Ces nanotubes présentent des caractéristiques thermiques uniques et sont fréquemment employés dans le contexte des transferts thermiques.



**Figure 2 : Nanotubes de carbone** **Figure 3 : Nanoparticules sphérique**

## **I.2. Fabrication et préparation des nanofluides :**

L'élaboration de nanoparticules implique divers procédés de fabrication qui se classent en deux grandes catégories distinctes :

Les procédés physiques, qui incluent des techniques telles que le broyage mécanique, visant à réduire la taille des particules par des moyens purement mécaniques.

Les procédés chimiques, qui englobent des méthodes telles que la pyrolyse ou la préparation chimique. Ces approches reposent sur des réactions chimiques pour créer des nanoparticules.

En parallèle, pour la production de nanofluides, il existe deux méthodes principales :

### ➤ Procédé en une étape:

La méthode en une étape, également connue sous le nom de méthode en une seule étape, implique la production directe des nanoparticules dans le fluide de base, comme illustré dans la Figure II.13. Bien que moins courante à des fins industrielles, cette méthode s'avère particulièrement utile pour certains types spécifiques de nanofluides. Elle présente l'avantage d'éviter les problèmes d'agglomération et d'oxydation des nanoparticules.

Prenons, par exemple, la technique d'ablation laser, qui représente une méthode écologique pour la préparation de nanoparticules métalliques. Cette technique offre un moyen unique de fabriquer des nanoparticules de manière précise et contrôlée [5]. Une autre application du processus en une étape implique la condensation d'une vapeur métallique dans un réacteur, ce qui permet la formation de nanoparticules sur un film de liquide à basse pression de vapeur.

Bien que moins courante que d'autres méthodes, la méthode en une étape s'avère extrêmement précieuse pour la production de nanofluides dans des conditions spécifiques, en minimisant les problèmes potentiels liés à la manipulation des nanoparticules. Elle offre une approche alternative et efficace pour la fabrication de ces matériaux à l'échelle nanométrique.





Figure 4 : One-step method stages for preparing nanofluids [6].

### ➤ Procédé en deux étapes:

La méthode en deux étapes, Tout d'abord, Les nanoparticules sont fabriquées, puis elles sont réparties au sein du liquide de base(voir Figure II.14). Cependant, pour garantir

## Chapitre I Généralités sur les nanofluides

une dispersion efficace et briser les agglomérats éventuels une action mécanique intensive est souvent nécessaire, impliquant l'utilisation d'un agitateur rotatif et d'ultrasons.. De plus, pour prévenir l'agglomération causée par l'interaction des forces d'attraction entre les particules, ainsi que les forces de répulsion électrostatiques sont utilisées en modifiant la surface des particules en adaptant la valeur du pH (approche covalente). Des forces de répulsion stériques peuvent également être utilisées en utilisant des molécules adsorbées à la surface (approche non covalente) [8].



**Figure 5 : Two-step method stages for preparing nanofluids [6,7]**

### **I.3. Propriétés thermo physiques des nanofluides :**

L'incorporation de nanoparticules dans un liquide apporte des modifications significatives aux propriétés thermophysiques de la solution. De multiples facteurs exercent leur influence sur ces changements, notamment le choix du matériau, la dimension et la forme des nanoparticules employées, la densité de particules en suspension dans le volume, ainsi que la capacité conductrice du liquide de base. Bien que d'importants travaux de recherche aient été entrepris pour élucider les mécanismes sous-jacents à ces variations, une phénoménologie concise et satisfaisante demeure en cours de développement.

Les propriétés physiques des nanofluides subissent des altérations suite à l'introduction de nanoparticules, touchant des aspects tels que la masse volumique, la chaleur spécifique, la conductivité thermique, la viscosité dynamique, entre autres. De multiples recherches ont été entreprises pour mesurer, expliquer et anticiper l'accroissement de la conductivité thermique des nanofluides. Plusieurs méthodes ont été utilisées à cette fin, la plus répandue étant celle qui repose sur un fil chaud en régime transitoire [9].

## **Chapitre I Généralités sur les nanofluides**

Il est essentiel de reconnaître que les propriétés physiques du nanofluide sont essentiellement déterminées par les caractéristiques du fluide de base liquide ainsi que par la phase dispersée constituée des nanoparticules solides. Cette approche nous amène à revisiter les propriétés intrinsèques de chacun de ces composants, à savoir le fluide de base et les nanoparticules [10]. Cette démarche est fondamentale pour comprendre pleinement les modifications induites par l'incorporation de nanoparticules dans le fluide de base.

### **I.3.1. la fraction volumique :**

La fraction volumique est une grandeur sans dimension qui exprime la proportion relative entre deux volumes, à savoir le volume des nanoparticules solides et le volume total, comprenant à la fois les nanoparticules et le fluide de base. Sa valeur varie de 0, représentant le fluide de base pur, à 1, qui signifie une concentration totale de nanoparticules. La fraction volumique se calcule en utilisant la formule suivante :

$$\varphi = \frac{\text{Volumesolide}}{\text{Volumetotaled'unnanofluide}} = \frac{V_p}{V_t}$$

### **I.3.2. Conductivité thermique (K) :**

La conductivité thermique se révèle être la propriété la plus cruciale des nanofluides. En effet, l'intégration de nanoparticules dans le liquide de base vise principalement à accroître cette conductivité thermique. Les modèles conventionnels destinés à décrire la capacité de transmission de la chaleur dans les mélanges composés de solides et de liquides ne sont généralement pas précis lorsque l'on aborde les nanofluides [1]. Par conséquent, de nombreux chercheurs ont entrepris d'introduire divers mécanismes influents et ont élaboré de nouveaux modèles afin de mieux appréhender la conductivité thermique des nanofluides.

La littérature scientifique regorge de travaux qui se focalisent sur l'optimisation de la capacité de conduction thermique dans les nanofluides. Dans la suite de ce travail, nous examinerons diverses approches théoriques élaborées pour essayer de rendre compte de ce phénomène :

#### **a) Modèle de Maxwell :**

Maxwell a présenté un modèle visant à estimer la capacité de conduction thermique d'un nanofluide en relation avec sa proportion volumique de nanomatériaux. Cependant, il est important de noter que ce modèle s'applique exclusivement à les nanofluides

## Chapitre I Généralités sur les nanofluides

qui renferment des nanoparticules de forme sphérique. Cette limitation peut être perçue comme une restriction du modèle, car il contraint l'utilisation de celui-ci aux seules nanoparticules de forme sphérique.

Le modèle de Maxwell [11] a été l'un des tout premiers à étudier de manière analytique la transmission de la chaleur dans un liquide avec des particules sphériques en suspension, en négligeant les interactions entre ces particules. L'équation obtenue est la suivante :

$$K_{nf} = \frac{K_s + 2K_f + 2\phi(K_s - K_f)}{(K_s + 2K_f) - \phi(K_s - K_f)}$$

Où :

**$K_{nf}$**  : correspond à la conductivité thermique du nanofluide

**$k_f$**  : désigne la conductivité thermique du liquide porteur

**$k_s$**  : représente la conductivité thermique des particules solides,

**$\phi$**  : indique la proportion volumique des particules en suspension dans le nanofluide..

### **b) Modèle de Hamilton – Crosser (1962) :**

Le modèle de Hamilton [12] constitue une expansion du modèle de Maxwell. Alors que ce dernier est limité aux particules sphériques, ce qui le rend moins efficace pour décrire le phénomène étudié, Le modèle de Hamilton et Crosser a été élaboré dans le but de faciliter le calcul plus efficient de la conductivité thermique du nanofluide, indépendamment de sa configuration des nanoparticules. Cette amélioration a été réalisée en introduisant un concept clé, le paramètre géométrique désigné sous le nom de sphéricité.. La sphéricité est définie comme le rapport entre la surface d'une sphère possédant un volume équivalent à celui des nanoparticules et une surface équivalente à celle d'une nanoparticule spécifique. La capacité de conduction thermique est exprimée à l'aide de l'équation suivante:

$$\frac{K_{nf}}{K_f} = \frac{K_s + (n - 1)K_f - (n - 1)(K_f - K_s)\phi}{K_s + (n - 1)K_f + (K_f - K_s)\phi}$$

L'équation de la conductivité thermique du nanofluide basée sur le modèle de Hamilton et Crosser inclut le paramètre de forme empirique  $n$ , qui est donné par  $n = 3$  lorsque les particules sont sphériques. La valeur de  $n$  est calculée en fonction de la sphéricité, représentée par le rapport entre la surface d'une sphère possédant le même volume que les nanoparticules et la surface d'une nanoparticule individuelle, ainsi que de la concentration volumique des

## Chapitre I Généralités sur les nanofluides

nanoparticules dans le fluide, notée  $\varphi$ . Cette équation permet de prendre en compte la forme des nanoparticules dans le calcul de la conductivité thermique du nanofluide.

### c) **Modèle de Yu et Choi :**

Le modèle proposé par Yu et Choi [13] Pour déterminer la capacité de conduction thermique repose sur l'idée de Décrire les nanofluides comme étant d'un liquide de base dans lequel sont dispersées des particules solides, espacées les unes des autres par une fine couche nanométrique. Cette couche joue le rôle d'un pont thermique qui facilite le transfert de chaleur entre le fluide et les nanoparticules. De manière intéressante, Ils ont présumé que la conductivité thermique de cette fine couche nanométrique est supérieure que celle du liquide de base.

Le modèle de Maxwell, formulé par Yu et Choi, est donné par l'équation suivante :

$$K_{nf} = \frac{K_s + 2K_f + 2\varphi(K_s - K_f)(1 + \beta)^3}{K_s + 2K_f - \varphi(K_s - K_f)(1 + \beta)^3} K_f$$

Le paramètre  $\beta$  représente le rapport entre l'épaisseur de la couche nanométrique et le rayon des particules

### d) **Bhattacharya et al :**

Bhattacharya et al. [14] en 2004 ont développé une nouvelle relation théorique qui ressemble à la formule de Xuan et Roetzel, mais qui prend en compte le mouvement Brownien des particules dans les nanofluides. Le mouvement Brownien peut être décrit mathématiquement comme les déplacements aléatoires des nanoparticules à l'intérieur du liquide de base.

Ce déplacement découle des chocs entre les nanoparticules et les molécules du liquide de base, ces dernières se déplaçant dans toutes les directions. Elles changent de trajectoire en raison de l'agitation thermique. Les nanoparticules sont de taille suffisamment réduite pour être détournées par les collisions, ce qui les amène à parcourir de très courtes distances avant d'être redirigées dans une autre direction après de nouvelles collisions, et ainsi de suite. Ce phénomène crée un mouvement global chaotique connu sous le nom de mouvement brownien.

La formule pour la conductivité thermique déterminée par Bhattacharya et ses collaborateurs..tient compte de ce mouvement Brownien et est exprimée comme suit :

$$K_{nf} = K_s \phi + (1 - \phi)K_f$$

### **I.3.3. Viscosité dynamique ( $\mu$ ) :**

La viscosité est une propriété qui caractérise la capacité d'un fluide à s'écouler, et son importance est considérable dans le cadre des applications pratiques, car elle influe directement sur la résistance au flux et la perte de pression lors de la convection forcée. En général, l'incorporation de particules solides dans un liquide entraîne une hausse de la viscosité du mélange résultant., bien que cette augmentation puisse varier considérablement en fonction de plusieurs facteurs.

Lorsque l'on utilise des nanoparticules identiques en termes de nature et de taille, ainsi qu'un fluide de base identique, plusieurs variables entrent en jeu, cela dépend principalement de la qualité de la dispersion des nanoparticules dans le fluide ainsi que de la température. Ces facteurs peuvent avoir un impact significatif sur la viscosité résultante du nanofluide. Par conséquent, pour rendre les nanofluides utilisables dans des applications pratiques, il est essentiel d'étudier attentivement l'élévation de la viscosité par rapport aux liquides non mélangés.

Pour obtenir une meilleure compréhension de l'influence des nanoparticules sur la viscosité, de nombreuses relations et modèles ont été élaborés et présentés dans la littérature scientifique. Ces modèles visent à expliquer comment les caractéristiques des nanoparticules et leur dispersion dans le fluide de base influencent la viscosité du nanofluide résultant.

#### **a) Modèle d'Einstein :**

En 1906, Einstein [15] s'est distingué en réalisant la première investigation concernant la viscosité dynamique d'un mélange comprenant des suspensions diluées de particules fines.. Ces particules étaient sphériques, rigides, et Présentes à une faible concentration volumique. Les conclusions de son étude ont abouti à la formulation de la relation suivante :

$$\mu_{nf} = \mu_f(1 + 2.5\phi)$$

Il convient de souligner que cette corrélation est applicable uniquement lorsque la fraction volumique des nanoparticules ( $\phi$ ) est égale à 0,03. Elle est utilisée pour estimer la viscosité dynamique du nanofluide ( $\mu_{nf}$ ) en relation avec la viscosité dynamique du fluide de base ( $\mu_f$ ) dans le contexte de suspensions diluées de particules sphériques et rigides.

#### **b) Modèle de Brinkman :**



## **Chapitre I Généralités sur les nanofluides**

En 1952, Brinkman [16] a élargi l'équation d'Einstein pour inclure un éventail plus étendu de concentrations volumiques. Sa relation permet de retrouver la relation d'Einstein dans le cas des faibles fractions volumiques. Cette extension a contribué à une meilleure compréhension du comportement de la viscosité dynamique dans des mélanges contenant des particules en suspension, même à des concentrations plus élevées.

$$\mu_{nf} = \frac{\mu_f}{(1 - \phi)^{2.5}}$$

Il est important de mentionner que pour de faibles fractions volumiques, la corrélation de Brinkman aboutit précisément à celle d'Einstein. Cependant, il est essentiel de comprendre que ces équations ne tiennent pas compte des influences du mouvement brownien ni de la taille des particules. Elles sont valables dans des conditions spécifiques et ne tiennent pas compte de certains facteurs qui peuvent être importants dans des situations différentes.

### **c) Modèle de Batchelor**

En prenant en considération l'impact du mouvement brownien et en supposant une dispersion isotrope de nanoparticules solides et sphériques, Batchelor [17] a élaboré une équation de viscosité qui élargit le modèle d'Einstein. Il a également démontré que la viscosité ne varie pas de manière proportionnelle avec la fraction volumique des nanoparticules ( $\phi$ ), mais plutôt de manière non linéaire avec la présence d'un terme en  $\phi^2$ . Le modèle de Batchelor pour la viscosité des nanofluides est formulé comme suit :

$$\mu_{nf} = \mu_f (1 + \eta\phi + kH\phi^2)$$

L'équation de Batchelor pour la viscosité des nanofluides prend en compte la viscosité intrinsèque ( $\eta$ ) et le coefficient de Huggins ( $kH$ ). Pour des particules sphériques, les valeurs typiques de  $\eta$  et de  $kH$  sont respectivement de 2.5 et 6.5. Cette équation est applicable pour le calcul de la viscosité des suspensions de nanoparticules lorsque la fraction volumique ( $\phi$ ) dépasse 10%.

### **d) Modèle Maiga et al**

D'autres relations et corrélations ont été élaborées dans la littérature pour des applications spécifiques. Par exemple, Maiga et ses collaborateurs [18] ont proposé une corrélation basée sur des résultats expérimentaux, qui peut être formulée comme suit :

$$\mu_{nf} = \mu_f (12.3\phi^2 + 7.3\phi + 1)$$

## Chapitre I Généralités sur les nanofluides

### e) Modèle Pack et Cho

Pack et Cho [19] ont élaboré un modèle pour calculer la viscosité des nanofluides en relation avec la fraction volumique des nanoparticules Al<sub>2</sub>O<sub>3</sub> dispersées dans l'eau, en utilisant la température ambiante comme point de référence. Leur étude a révélé une réduction de la viscosité du nanofluide à mesure que la température augmente. Voici le modèle proposé :

$$\mu_{nf} = \mu_f (533.9\varphi^2 + 39.11\varphi + 1)$$

### I.3.4. La masse volumique ( $\rho$ ) :

La détermination de la masse volumique d'un nanofluide, où les nanoparticules sont parfaitement dispersées dans le fluide à une température donnée, peut être effectuée en utilisant Lorsque l'on considère un mélange, la masse volumique est définie en utilisant la relation suivante :

$$\rho = \frac{m}{v} = \frac{m_f + m_s}{v_f + v_s} = \frac{\rho_f V_f + \rho_s V_s}{V_f + V_s}$$

Ainsi, nous pouvons déduire la masse volumique du nanofluide en utilisant la relation suivante :

$$\rho_{nf} = (1 - \varphi)\rho_f + \varphi\rho_s$$

tout à fait. Dans cette relation, les symboles représentent les quantités suivantes :

$\rho_{nf}$  représente la masse volumique du nanofluide.

$\rho_f$  désigne la masse volumique du fluide de base.

$\rho_s$  correspond à la masse volumique des nanoparticules.

### I.3.5. La chaleur massique ( $C_p$ ) :

Tout à fait, vous avez raison. La chaleur massique (ou chaleur spécifique) est une propriété importante qui mesure la capacité d'une substance à emmagasiner de la chaleur. Plus précisément, la chaleur massique représente la chaleur requise pour élever la température d'une quantité standard d'une substance d'un degré d'une unité de température (habituellement 1 Kelvin ou 1 degré Celsius) lors d'une transformation spécifique, comme une augmentation de température.

La chaleur massique est exprimée en joules par kilogramme par Kelvin (J/kg·K) dans le cadre du Système international d'unités (SI). Elle peut varier d'une substance à l'autre et

## **Chapitre I Généralités sur les nanofluides**

dépend des propriétés moléculaires et de la structure de la substance. Cette propriété est essentielle pour comprendre comment la chaleur est stockée, transférée et utilisée dans divers processus et systèmes thermiques.

### **I.4. Applications des Nanofluides**

Les nanofluides, constitués de nanoparticules (de 1 à 200 nm) dispersées dans un fluide de base, sont des matériaux particulièrement intéressants pour une variété d'applications. Ces fluides de base englobent une gamme diversifiée de liquides couramment utilisés dans différents contextes, parmi lesquels on trouve l'eau, les liquides organiques tels que l'éthylène et les triéthylènes glycols, les huiles et lubrifiants, les biofluides, les solutions de polymères, et bien d'autres.

Les nanoparticules incorporées dans ces nanofluides sont également très variées et comprennent des métaux qui ne subissent pas de réactions chimiques significatives comme l'or et le cuivre, des oxydes métalliques tels que l'alumine, la silice, la zircone et l'oxyde de titane, ainsi que des céramiques oxydées comme l' $\text{Al}_2\text{O}_3$  et le  $\text{CuO}$ . D'autres nanoparticules sont issues de carbures métalliques (comme le  $\text{SiC}$ ) et de nitrures métalliques (tel que l' $\text{AlN}$  et le  $\text{SiN}$ ), ainsi que de formes diverses de carbone, y compris le diamant, le graphite, les nanotubes de carbone (NTC) et les fullerènes. De plus, il existe des nanoparticules fonctionnalisées qui peuvent être spécialement modifiées pour des applications particulières.

En fonction de leur emploi particulier, les nanofluides peuvent être regroupés en plusieurs catégories, notamment les nanofluides caloporteurs, qui sont destinés à améliorer la capacité de transfert de chaleur, les nanofluides tribologiques, qui sont utilisés dans les systèmes de lubrification et de friction, les nanofluides surfactants et de revêtement pour des applications de surface, les nanofluides chimiques, les nanofluides utilisés dans les processus d'extraction, les nanofluides destinés à des applications environnementales pour la dépollution, les nanofluides employés dans le domaine pharmaceutique et biologique, ainsi que les nanofluides médicaux qui sont étudiés pour leurs interactions avec les tissus et les cellules dans le domaine médical. Cette diversité d'applications témoigne de l'importance croissante des nanofluides dans la recherche et l'industrie.

#### **I.4.1. Systèmes de réfrigération :**

Les nanofluides ont des applications potentielles dans les systèmes de refroidissement en tant que nanoréfrigérants et nanolubrifiants. Ils ont le potentiel d'augmenter les

## **Chapitre I Généralités sur les nanofluides**

performances thermodynamiques et mécaniques du système de réfrigération en augmentant les propriétés de transport et en améliorant la lubrification dans les compresseurs [20]

### **I.4.2. Systèmes d'énergie solaire :**

Les nanofluides sont susceptibles d'être employés dans les systèmes d'énergie solaire pour optimiser l'absorption et la conversion de l'énergie solaire, en exploitant des nanofluides en tant que liquides de transfert de chaleur dans les collecteurs solaires il est envisageable d'optimiser l'efficacité du transfert de chaleur [21]

### **I.4.3. Applications électroniques :**

Les nanofluides peuvent être utilisés dans les applications électroniques pour améliorer le refroidissement des composants électroniques. Les nanofluides peuvent améliorer la conductivité thermique et faciliter la dissipation de la chaleur générée par les composants électroniques .[22]

### **I.4.4. Moteurs à combustion interne :**

Les nanofluides peuvent servir de liquide de refroidissement dans les moteurs à combustion interne afin d'augmenter le transfert de chaleur et d'améliorer les performances de refroidissement. L'utilisation de nanofluides comme liquide de refroidissement peut entraîner une réduction de la consommation de carburant et améliorer les performances du moteur .[23]

### **I.4.5. Applications de refroidissement industriel :**

Les nanofluides ont des applications potentielles dans les systèmes de refroidissement industriel en vue d'accroître l'efficacité du transfert de chaleur. Les nanofluides peuvent augmenter les propriétés de transfert de chaleur des liquides de base, ce qui peut conduire à une amélioration significative des performances des échangeurs de chaleur.[24]

### **I.4.6. Chauffage des bâtiments :**

Les nanofluides peuvent être employés pour augmenter l'efficacité du transfert de chaleur dans les systèmes de chauffage des bâtiments.. Les nanofluides peuvent augmenter la conductivité thermique des fluides de chauffage, ce qui peut conduire à une meilleure efficacité du système de chauffage .[25]

## **Chapitre I Généralités sur les nanofluides**

### **I.4.7. Refroidissement des systèmes nucléaires :**

Les nanofluides peuvent être appliqués dans le refroidissement des systèmes nucléaires afin d'optimiser le transfert de chaleur. Les nanofluides contenant des nanotubes de carbone peuvent présenter une conductivité thermique plus élevée, ce qui peut améliorer l'efficacité du refroidissement dans les réacteurs nucléaires (Kim et al., 2011).[26]

### **I.4.8. Espace et défense :**

Les nanofluides peuvent être utilisés dans les applications spatiales et de défense pour améliorer le refroidissement des systèmes électroniques et des équipements. Les nanofluides peuvent aider à dissiper la chaleur générée dans des environnements extrêmes, améliorant ainsi la performance et la durabilité des systèmes.[27]

### **I.4.9. Stockage d'énergie :**

L'utilisation de nanofluides dans le stockage d'énergie peut entraîner une amélioration des performances des matériaux de stockage thermique. Les nanoparticules présentes dans les nanofluides peuvent augmenter la conductivité thermique des matériaux de stockage, permettant une meilleure efficacité du stockage et de la libération d'énergie .[28]

### **I.4.10. Applications mécaniques :**

Les nanofluides peuvent être utilisés dans diverses applications pour maximiser l'efficacité du transfert de chaleur et les propriétés tribologiques. Par exemple, les nanofluides peuvent être utilisés comme lubrifiants améliorés pour réduire les frottements et l'usure dans les paliers magnétiques .[29]

### **I.4.11. Activité antibactérienne :**

Les nanofluides peuvent présenter une activité antibactérienne en raison de l'incorporation de nanoparticules antimicrobiennes. Ces nanofluides peuvent être utilisés pour lutter contre les pathogènes présents dans l'eau, offrant ainsi une méthode de traitement de l'eau efficace .[30]

### **I.4.12. Palier magnétique :**

Les nanofluides peuvent être utilisés dans les paliers magnétiques pour améliorer les propriétés de lubrification et réduire les frottements. Les nanofluides peuvent aider à

## **Chapitre I Généralités sur les nanofluides**

maintenir un fonctionnement fluide et sans contact des paliers magnétiques, ce qui contribue à une amélioration de la performance et une prolongation de la durée de vie des systèmes..[31]

### **I.5. Les avantages des nanofluides :**

L'utilisation d'un nanofluide efficace peut indéniablement améliorer l'efficacité d'un système de refroidissement liquide sans entraîner d'augmentation du niveau sonore ni de la consommation d'énergie. En réalité, grâce à une meilleure efficacité globale, il est envisageable de diminuer la ventilation ou d'utiliser une pompe moins puissante tout en maintenant les mêmes performances, ce qui est particulièrement avantageux si le fonctionnement silencieux est une priorité. Les nanofluides présentent plusieurs avantages importants :

- Une surface de transfert de chaleur étendue:

Les nanofluides contiennent des nanoparticules qui ont une taille réduite par rapport aux particules conventionnelles. Du fait de leur dimension réduite, les nanoparticules offrent une surface spécifique plus importante par unité de volume, ce qui augmente considérablement la surface de transfert de chaleur. Cette caractéristique permet une meilleure dissipation thermique et une amélioration de l'efficacité du transfert thermique [32].

- Volume réduit :

Les nanofluides nécessitent des concentrations de nanoparticules relativement faibles pour obtenir des améliorations significatives des propriétés thermiques. En raison de cette faible concentration, le volume total de nanofluides requis est souvent inférieur à celui des fluides traditionnels utilisés dans les mêmes applications. Cela contribue à économiser de l'espace et simplifie l'intégration des nanofluides dans différents systèmes [33].

- Moindre colmatage des particules :

Les nanoparticules présentes dans les nanofluides ont une taille réduite, ce qui réduit le risque de colmatage des canaux ou des conduits à travers lesquels le fluide circule. Comparées aux particules plus grandes, les nanoparticules ont une plus grande probabilité de suivre le flux du liquide, évitant ainsi l'accumulation excessive et le colmatage. Cela contribue à maintenir la performance des systèmes utilisant des nanofluides à long terme [34].

- Propriétés ajustables :

## **Chapitre I Généralités sur les nanofluides**

Les nanofluides offrent la possibilité d'ajuster leurs propriétés en modifiant la nature des nanoparticules utilisées, leur concentration et même le liquide de base. Ces ajustements permettent d'optimiser les caractéristiques des nanofluides pour des applications spécifiques, en fonction des exigences de transfert de chaleur, de viscosité ou d'autres propriétés thermiques souhaitées [35].

Ces avantages soulignent l'attrait des nanofluides dans le domaine du refroidissement liquide et démontrent leur potentiel en vue d'optimiser les performances thermiques des systèmes de manière efficace et efficiente.

### **I.6. Les inconvénients des nanofluides :**

Les nanofluides présentent également certains inconvénients et défis associés à leur utilisation. Voici une explication détaillée de ces inconvénients, accompagnée de références pour approfondir les informations :

- Manque d'accord entre les résultats :

Il existe souvent un manque d'accord entre les résultats expérimentaux et théoriques concernant les propriétés des nanofluides. Cela est dû à la complexité des interactions entre les nanoparticules et le liquide de base, ainsi qu'à la variabilité des méthodes expérimentales utilisées pour caractériser les nanofluides. Ce manque d'accord peut rendre difficile la comparaison des résultats et la formulation de modèles prédictifs précis [36].

- Compréhension théorique limitée :

Malgré de nombreuses recherches, la compréhension théorique des mécanismes de transfert de chaleur et de la stabilité des nanofluides reste limitée. Les phénomènes complexes tels que l'agrégation des nanoparticules, la convection mixte et les interactions nanoparticules-interface liquide nécessitent encore des études approfondies pour une compréhension complète [37].

- Instabilité de la dispersion des nanoparticules :

Les nanofluides sont sujets à l'agglomération ou à la sédimentation des nanoparticules avec le temps, ce qui peut potentiellement entraîner une instabilité de la dispersion. Les forces de Van der Waals et les interactions électrostatiques et les gradients de concentration peuvent favoriser l'agglomération, limitant ainsi l'efficacité et la stabilité à long terme des nanofluides [38].

## **Chapitre I Généralités sur les nanofluides**

- Chute de pression accrue :

L'incorporation de nanoparticules dans les nanofluides peut provoquer une augmentation de la perte de pression dans les systèmes de circulation. Cela peut poser des défis en termes de conception et d'efficacité énergétique des dispositifs utilisant des nanofluides, nécessitant parfois des pompes plus puissantes pour maintenir un débit adéquat [39].

- Coût élevé :

Les nanofluides peuvent être plus coûteux à fabriquer en raison de l'expensivité des nanoparticules, comparativement aux fluides classiques utilisés et des processus de fabrication complexes impliqués. Les coûts de production élevés peuvent constituer un obstacle à grande échelle pour l'utilisation généralisée des nanofluides dans certaines applications [40].

- Difficultés de production :

La production de nanofluides de haute qualité et de manière reproductible peut être un défi. La dispersion uniforme des nanoparticules dans le liquide de base, sans agglomération ni sédimentation, nécessite des méthodes de production sophistiquées et des protocoles de contrôle stricts, ce qui peut rendre la production de nanofluides plus complexe que celle des fluides traditionnels [41].

La production de nanofluides peut être techniquement complexe et présenter des défis liés à la dispersion homogène des nanoparticules dans le fluide de base. Cela peut rendre la production des nanofluides plus difficile par rapport aux fluides conventionnels.

### **I.7. Revue bibliographique**

Dans cette revue bibliographique, nous présentons les conclusions des études les plus récemment publiées sur les nanofluides et leurs applications.

- Choi, S. U. S. (1995) :

L'étude de Choi est une étude fondamentale dans le domaine des nanofluides. L'auteur a caractérisé les propriétés thermophysiques des nanofluides et a introduit le concept de nanofluides comme agent de transfert de chaleur amélioré par l'ajout de nanoparticules. Cela a été un point de départ pour de nombreuses recherches ultérieures.[42].

- Eastman, J. A. et al. (2001) :



## **Chapitre I Généralités sur les nanofluides**

Cette étude expérimentale a observé une élévation inhabituelle de la conductivité thermique dans les nanofluides contenant des nanoparticules de cuivre. Ces résultats ont attiré une attention considérable et ont suscité un intérêt croissant pour les nanofluides.[43].

- Xie, H. et al. (2002) :

Cette recherche a étudié l'influence de la concentration et de la taille des particules d'alumine sur la conductivité thermique des nanofluides. Les résultats ont révélé une augmentation notable de la conductivité thermique avec l'augmentation de la concentration de nanoparticules. [44].

- Das, S. K. et al. (2003) :

Dans cette étude, les chercheurs ont exploré comment la conductivité thermique des nanofluides varie en fonction de la température. Ils ont réalisé des mesures expérimentales de la conductivité thermique de nanofluides composés d'eau et de nanoparticules de cuivre, et ont observé une augmentation de la conductivité thermique à mesure que la température augmentait..[45].

- Wang, X. Q. et al. (2007) :

Cette revue offre un aperçu des investigations théoriques et numériques sur les nanofluides. Elle aborde les modèles mathématiques, les simulations numériques et les techniques de modélisation utilisées pour étudier les propriétés des nanofluides, y compris la conductivité thermique.[46].

- Pastoriza-Gallego, M. J. et al. (2013) :

Cette revue a pour objectif principal d'analyser en détail la conductivité thermique des nanofluides. Elle offre un résumé des résultats issus d'expériences et de modèles théoriques, en mettant en lumière les facteurs qui exercent une influence sur la conductivité thermique de ces nanofluides..[47].

- Sundar, L. S. et al. (2018) :

Cette étude se concentre sur les applications des nanofluides en énergie solaire. Les chercheurs ont examiné l'effet des nanofluides sur l'efficacité des collecteurs solaires thermiques. Les résultats ont démontré que l'emploi de nanofluides conduisait à améliorer l'absorption de la chaleur et donc l'efficacité globale du système.[48].

- Wang, B. et al. (2019) :

Cette étude examine l'effet des nanofluides sur l'efficacité énergétique des systèmes de refroidissement. Les chercheurs ont réalisé des expériences pour évaluer l'amélioration de l'efficacité du transfert thermique au sein d'un échangeur de chaleur utilisant des nanofluides à base d'oxyde de zinc. Les résultats ont révélé une amélioration notable de l'efficacité de refroidissement par rapport à l'utilisation de fluides traditionnels.[49].

## **Chapitre I Généralités sur les nanofluides**

### **conclusion**

Les nanofluides sont des liquides qui contiennent des nanoparticules ou des nanotubes dispersés dans la matrice du liquide. Les nanofluides peuvent être utilisés dans de nombreux domaines tels que le refroidissement électronique, la production d'énergie, l'ingénierie aérospatiale, la biologie et la médecine.

Les nanofluides offrent de multiples avantages, tels que l'accroissement de la conductivité thermique et de la capacité de transfert de chaleur, la réduction de la viscosité et de la densité du liquide, ainsi que l'amélioration de la stabilité thermique et chimique. Les nanofluides peuvent également être utilisés pour améliorer l'efficacité des échangeurs de chaleur ainsi que des systèmes de refroidissement.

Bien que les nanofluides représentent une technologie passionnante et prometteuse, il existe encore des défis à surmonter. Les méthodes de production et de dispersion des nanoparticules doivent être optimisées pour obtenir une dispersion homogène et stable dans la matrice liquide. Les coûts de production des nanoparticules peuvent également représenter un défi économique.

Il est essentiel de prendre en compte les répercussions sur l'environnement par les nanofluides. Les nanoparticules sont des matériaux qui peuvent influencer l'environnement et la santé humaine s'ils sont rejetés dans l'environnement. Les investigations à venir devront se focaliser sur l'analyse de l'impact environnemental des nanofluides à travers leur cycle de vie.

Les nanofluides représentent une technologie innovante ayant le potentiel d'améliorer de divers secteurs de la science et de l'industrie. Cependant, il est important d'optimiser les méthodes de production et de dispersion des nanoparticules, d'abaisser les coûts de fabrication et de considérer les impacts environnementaux pour permettre une utilisation sûre et durable des nanofluides.

### Références

- [1] Yu, W., & Choi, S. U. S. (2003). The role of interfacial layers in the enhanced thermal conductivity of nanofluids: a renovated Maxwell model. *Journal of nanoparticle research*, 5, 167-171.
- [2] Michaelides, E. E. (2014). Thermodynamic and Transport Properties. Michaelides, E. E. (2014). Thermodynamic and Transport Properties.
- [4] Xuan, Y., & Li, Q. (2003). Heat transfer enhancement of nanofluids. *International Journal of Heat and Fluid Flow*, 21(1), 58-64.
- [5] Reza Sadrolhosseini, A.; Adzir Mahdi, M.; Alizadeh, F.; Abdul Rashid, S. Laser Ablation Technique for Synthesis of Metal Nanoparticle in Liquid. In *Laser Technology and its Applications*; Ma, Y., Ed.; IntechOpen, 2019 ISBN 978-1-78984-917-2.
- [6] S. Mukherjee, S. Paria, Preparation and stability of nanofluids-a review, *IOSR-JMCE*, 9 (2013) 63-69.
- [7] Yang, L.; Hu, Y. Toward TiO<sub>2</sub> Nanofluids—Part 1: Preparation and Properties. *Nanoscale Research Letters* 2017, 12, doi:10.1186/s11671-017-2184-8.
- [8] Khodja M. Les fluides de forage: Etude des performances et considérations environnementales, INSA Toulouse, 2008.
- [9] Stéphane, F., Guillaume, P., & Catalin, P. (2012). Nanofluides et transfert de chaleur par convection naturelle. *Journée Thématique SFT–Paris*, 15.
- [10] LAMRIZeggar Asma, Contribution à l'Etude Théorique des Transferts Thermiques Convectifs dans un Nanofluide. Application aux Modèles Monophasique et Diphasique, Thèse de Magister, Université de Frères Mentouri, 2014.
- [11] J.C. Maxwell. A Treatise on electricity and magnetism, Clarendon Press, U.K., (1891)
- [12] R.L. Hamilton and O.K. Crosser. Thermal conductivity of heterogeneous two component systems. *Industrial and Engineering Chemistry Fundamentals* 1(3), 187-191, 1962.
- [13] W. Yu, S. U. S. Choi. The role of interfacial layers in the enhanced thermal conductivity of nanofluids: a renovated Maxwell model. *J. nanoparticle Res* 5: 167-71, 2003.
- [14] Bhattacharya P, Saha SK, Yadav A, Phelan PE, Prasher RS. Brownian dynamics simulation to determine the effective thermal conductivity of nanofluids. *Journal Applied Physics* 2004; 95(11):6492–4
- [15] A. Einstein. *Investigations on the Theory of the Brownian Movement*. Dover Publications, New York, 1956
- [16] Brinkman HC. The viscosity of concentrated suspensions and solution. *Journal of Chemical Physics* 1952;20:571–81.
- [17] Batchelor, G. (1976). Brownian diffusion of particles with hydrodynamic interaction. *Journal of Fluid Mechanics*, 74(1), 1-29.
- [18] Maiga, S. E. B., Palm, S. J., Nguyen, C. T., Roy, G., Galanis, N. (2005). Heat transfer enhancement by using nanofluids in forced convection flows. *International journal of heat and fluid flow*, 26(4), 530- 546.
- [19] Pak, B. C., & Cho, Y. I. (1998). Hydrodynamic and heat transfer study of dispersed fluids with submicron metallic oxide particles. *Experimental Heat Transfer an International Journal*, 11(2), 151-170.

## **Chapitre I Généralités sur les nanofluides**

- [20] Nguyen, C. T., Roy, G., Gauthier, C., & Galanis, N. (2007). Heat transfer enhancement using Al<sub>2</sub>O<sub>3</sub>–water nanofluid for an electronic liquid cooling system. *Applied Thermal Engineering*, 27(8-9), 1501-1506.
- [21] Taylor, R. A., Phelan, P. E., Otonicar, T. P., Adrian, R., & Prasher, R. (2011). Nanofluid optical property characterization: towards efficient direct absorption solar collectors. *Nanoscale research letters*, 6, 1-11.
- [22] Yu, W., & Choi, S. U. S. (2003). The role of interfacial layers in the enhanced thermal conductivity of nanofluids: a renovated Maxwell model. *Journal of nanoparticle research*, 5, 167-171.
- [23] Saleh, H., Anwar, H., & Raji, A. (2016). Cooling performance and heat transfer characteristics of engine coolant-based Al<sub>2</sub>O<sub>3</sub> nanofluid for automotive applications. *International Communications in Heat and Mass Transfer*, 75, 60-69.
- [24] Eastman, J. A., Choi, S. U. S., Li, S., Yu, W., & Thompson, L. J. (2001). Anomalously increased effective thermal conductivities of ethylene glycol-based nanofluids containing copper nanoparticles. *Applied physics letters*, 78(6), 718-720.
- [25] Lee, S., & Choi, S. U. (1996). Application of metallic nanoparticle suspensions in advanced cooling systems (No. ANL/ET/CP-90558; CONF-961105-20). Argonne National Lab.(ANL), Argonne, IL (United States).
- [26] Lee, J. H., Kim, S. H., Lee, C. H., & Kim, S. (2012). Preparation and heat transfer properties of water-based nanofluids containing multi-walled carbon nanotubes. *Applied Thermal Engineering*, 37, 214-219.
- [27] Keblinski, P., Eastman, J. A., & Cahill, D. G. (2005). Nanofluids for thermal transport. *Materials today*, 8(6), 36-44.
- [28] Anoop, K. B., Kabelac, S., Sundararajan, T., & Das, S. K. (2009). Rheological and flow characteristics of nanofluids: Influence of electroviscous effects and particle agglomeration. *Journal of applied physics*, 106(3), 034909.
- [29] Xie, H., Lee, H., Youn, W., & Choi, M. (2003). Nanofluids containing multiwalled carbon nanotubes and their enhanced thermal conductivities. *Journal of Applied physics*, 94(8), 4967-4971.
- [30] Raghvendra, S., Praveen, B. M., Nemade, P. R., & Pandit, A. B. (2017). Antibacterial activity of copper oxide nanofluid against waterborne pathogens. *Desalination and Water Treatment*, 94, 132-140.
- [31] Buongiorno, J., Hu, L. W., & McKrell, T. (2009). Nanofluid coolants for advanced nuclear power plants. *Proceedings of the 12th International Topical Meeting on Nuclear Reactor Thermal-Hydraulics (NURETH-12)*, Paper No. 740.
- [32] Yu, W., & Xie, H. (2012). A review on nanofluids: preparation, stability mechanisms, and applications. *Journal of nanomaterials*, 2012, 1-17.
- [33] Wang, X., Xu, X., & Choi, S. U. (1999). Thermal conductivity of nanoparticle-fluid mixture. *Journal of thermophysics and heat transfer*, 13(4), 474-480.
- [34] Trisaksri, V., & Wongwises, S. (2007). Critical review of heat transfer characteristics of nanofluids. *Renewable and sustainable energy reviews*, 11(3), 512-523..
- [35] Wen, D., & Ding, Y. (2005). Experimental investigation into the pool boiling heat transfer of aqueous based  $\gamma$ -alumina nanofluids. *Journal of Nanoparticle Research*, 7, 265-274.
- [36] Keblinski, P., Phillpot, S. R., Choi, S. U. S., & Eastman, J. A. (2002). Mechanisms of heat flow in suspensions of nano-sized particles (nanofluids). *International journal of heat and mass transfer*, 45(4), 855-863.
- [37] Wang, X. Q., & Mujumdar, A. S. (2007). Heat transfer characteristics of nanofluids: a review. *International journal of thermal sciences*, 46(1), 1-19.
- [38] Wen, D., & Ding, Y. (2005). Experimental investigation into the pool boiling heat transfer of aqueous based  $\gamma$ -alumina nanofluids. *Journal of Nanoparticle Research*, 7, 265-274.

## **Chapitre I Généralités sur les nanofluides**

- [39] Xuan, Y., & Li, Q. (2003). Investigation on convective heat transfer and flow features of nanofluids. *J. Heat transfer*, 125(1), 151-155.
- [40] Wong, K. V., & De Leon, O. (2010). Applications of nanofluids: current and future. *Advances in mechanical engineering*, 2, 519659.
- [41] Choi, S. U., & Eastman, J. A. (1995). Enhancing thermal conductivity of fluids with nanoparticles (No. ANL/MSD/CP-84938; CONF-951135-29). Argonne National Lab.(ANL), Argonne, IL (United States).
- [42] Choi, S. U., & Eastman, J. A. (1995). Enhancing thermal conductivity of fluids with nanoparticles (No. ANL/MSD/CP-84938; CONF-951135-29). Argonne National Lab.(ANL), Argonne, IL (United States).
- [43] Eastman, J. A., Choi, S. U. S., Li, S., Yu, W., & Thompson, L. J. (2001). Anomalous increase in effective thermal conductivities of ethylene glycol-based nanofluids containing copper nanoparticles. *Applied physics letters*, 78(6), 718-720.
- [44] Xie, H. Q., Wang, J. C., Xi, T. G., & Liu, Y. (2002). Thermal conductivity of suspensions containing nanosized SiC particles. *International Journal of Thermophysics*, 23, 571-580.
- [45] Das, S. K., Putra, N., Thiesen, P., & Roetzel, W. (2003). Temperature dependence of thermal conductivity enhancement for nanofluids. *J. Heat Transfer*, 125(4), 567-574.
- [46] Wang, X. Q., & Mujumdar, A. S. (2008). A review on nanofluids-part I: theoretical and numerical investigations. *Brazilian Journal of Chemical Engineering*, 25, 613-630.
- [47] Pastoriza-Gallego, M. J., Casanova, C., & Legido, J. L. (2013). Review on thermal properties of nanofluids. *Materials Science and Engineering: R: Reports*, 74(11), 365-383.
- [48] Sundar, L. S., Sharma, K. V., Malvarvizhi, S., & Srinivasan, P. S. S. (2018). Performance analysis of solar thermal systems using nanofluid as a heat transfer fluid. *Renewable Energy*, 119, 691-700.
- [49] Wang, B., Gao, D., Ma, C., & Lin, F. (2019). Experimental study on energy-saving potential of cooling system by using nanofluid. *Energy and Buildings*, 182, 222

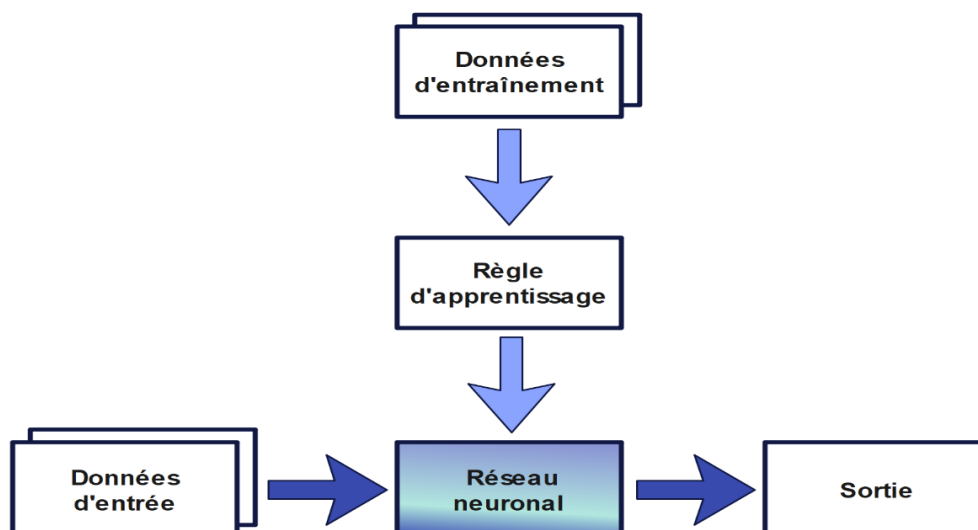
# ***CHAPITRE II***

### Introduction

Ce chapitre sert d'introduction aux réseaux neuronaux, qui sont largement utilisés comme modèle dans le contexte de l'apprentissage automatique. Les réseaux neuronaux ont une histoire riche en développement et ont donné lieu à de nombreuses avancées découlant de recherches approfondies. De nombreux ouvrages sont disponibles, se concentrant exclusivement sur les réseaux de neurones. Parallèlement à l'augmentation de l'intérêt envers le Deep Learning, les réseaux de neurones ont également acquis une importance considérable. Nous allons passer en revue brièvement les techniques pertinentes et pratiques pour mieux appréhender le domaine de l'apprentissage profond.

Pour ceux qui découvrent le concept de réseau de neurones, nous commencerons par les bases. Nous examinerons initialement comment les réseaux de neurones sont liés à l'apprentissage automatique. Les modèles d'apprentissage automatique peuvent prendre différentes formes, et les réseaux de neurones en font partie intégrante. La figure 2-1 illustre cette relation entre l'apprentissage automatique et les réseaux de neurones. Il est essentiel de noter que, dans le contexte des réseaux de neurones, le processus de détermination du modèle (c'est-à-dire les paramètres du réseau de neurones) est désigné comme la règle d'apprentissage.

Ce chapitre exposera les règles d'apprentissage spécifiques aux réseaux de neurones à une seule couche, tandis que les règles d'apprentissage pour les réseaux de neurones multicouches seront explorées dans les chapitres à venir.



**Figure 6 :La relation entre le Machine Learning et les réseaux de neurones**

### **II.1. Définition :**

Les Réseaux de Neurones Artificiels (RNA) sont des modèles informatiques qui tirent leur inspiration de la manière dont les réseaux neuronaux biologiques sont structurés et fonctionnent. Ils sont composés de nœuds interconnectés, appelés neurones artificiels ou perceptrons, organisés en couches. Chaque neurone reçoit des signaux d'entrée, leur applique une transformation mathématique, puis produit un signal de sortie qui est transmis à la couche suivante. Les connexions entre les neurones sont associées à des poids qui déterminent la force et l'importance du signal. Grâce à un processus appelé apprentissage, ces poids sont ajustés pour optimiser la capacité du réseau à effectuer une tâche spécifique, telle que la reconnaissance de motifs ou la prédiction. [1]

### **II.2. Historique sur les Réseaux de neurones**

- En 1890, le célèbre psychologue américain W. James a introduit le concept de mémoire associative, posant ainsi les fondations de ce qui évoluera par la suite en une loi fondamentale pour le fonctionnement de l'apprentissage dans les réseaux neuronaux, familièrement appelée la règle de Hebb. Cette loi de Hebb est un principe crucial dans le domaine de l'apprentissage neuronal, qui stipule que lorsqu'une cellule nerveuse A est activée simultanément avec une cellule nerveuse B, la connexion synaptique entre ces cellules est renforcée. En d'autres termes, elle énonce que "les cellules qui se déclenchent ensemble, se câblent ensemble", ce qui a des implications profondes dans la compréhension de la plasticité cérébrale et de l'apprentissage.[2]
- En 1943, John Mc Culloch et Walter Pitts , leur nom a été associé à une représentation du neurone biologique, donnant naissance à ce que l'on appelle le modèle de McCulloch-Pitts. Ce modèle représente un neurone dont le comportement est binaire, c'est-à-dire qu'il est basé sur des signaux d'activation ou d'inhibition. Leur travail pionnier a été le premier à prouvé que, au moins en principe, des réseaux de neurones formels simples ont la capacité d'exécuter des fonctions logiques, arithmétiques et symboliques complexes. Cette percée a jeté les fondations de la théorie des réseaux neuronaux artificiels et a ouvert la voie au développement ultérieur de l'apprentissage machine et l'IA.[3]



## **Chapitre II Réseaux De Neurones Artificiels**

- En 1949, le physiologiste américain Donald Hebb a formulé la célèbre loi de Hebb, qui explique le phénomène de conditionnement chez les animaux en se basant sur les propriétés des neurones eux-mêmes. Sa théorie a notamment été illustrée par l'exemple du conditionnement pavlovien, un exemple classique, lorsque qu'un chien est nourri à la même heure tous les jours, cela conduit à une sécrétion de salive chez l'animal à cette heure précise, même en l'absence de nourriture. La loi de Hebb suggère que les connexions entre les neurones se modifient en fonction de l'activité synaptique simultanée, ce qui contribue en partie à expliquer ce type de résultats expérimentaux.. Cette loi de Hebb a eu un impact significatif sur la compréhension des mécanismes de l'apprentissage et de la plasticité synaptique dans le domaine des neurosciences et a également influencé le développement ultérieur des réseaux de neurones artificiels.[4]

### **Les premiers succès**

- En 1957, Frank Rosenblatt a conçu le modèle Perceptron, une avancée significative dans le domaine des réseaux neuronaux artificiels. Il a développé le tout premier neuroordinateur basé sur ce modèle et l'a utilisé pour la reconnaissance de motifs. Il est essentiel de noter qu'à cette époque, les ressources technologiques étaient limitées, et il a accompli un exploit en réussissant à faire fonctionner cet appareil de manière stable pendant une période dépassant quelques minutes. Le Perceptron de Rosenblatt a ouvert la voie à de nombreuses recherches ultérieures sur les réseaux de neurones, jetant ainsi les bases de l'apprentissage supervisé, qui est aujourd'hui l'une des techniques fondamentales de l'apprentissage automatique et de l'intelligence artificielle.[5]
- En 1960, Bernard Widrow, un spécialiste de l'automatique, a créé le modèle Adaline (Adaptative Linear Element). Bien que ce modèle présente une structure similaire au Perceptron, il propose une loi d'apprentissage différente qui est à l'origine de l'algorithme de rétropropagation de gradient largement utilisé aujourd'hui avec les Perceptrons multicouches. Les réseaux de type Adaline sont encore employés de nos jours pour des applications spécifiques. À cette époque, B. Widrow a également fondé l'une des premières entreprises à proposer des neuroordinateurs et des neurocomposants, la "Memistor Corporation". Il est actuellement le président de l'International Neural Network Society (INNS), que nous aborderons plus en détail dans le chapitre sur les informations pratiques.[6]

## **Chapitre II Réseaux De Neurones Artificiels**

- En 1969, Marvin Minsky et Seymour Papert ont publié un ouvrage majeur qui a révélé les limitations théoriques du Perceptron, notamment son incapacité à résoudre des problèmes non linéaires. Leurs recherches ont implicitement étendu ces limitations à tous les modèles de réseaux de neurones artificiels. En conséquence, leur objectif a été atteint, ce qui a entraîné une réduction significative des investissements dans la recherche sur les réseaux de neurones, en particulier aux États-Unis. Les chercheurs ont alors principalement orienté leurs travaux vers le domaine de l'intelligence artificielle (IA) et des systèmes basés sur des règles. Cette période est couramment appelée "l'hiver de l'IA" en raison de la baisse des financements pour la recherche sur les réseaux de neurones.[7]

### **L'ombre**

- Entre 1967 et 1982, les travaux de recherche consacrés aux réseaux de neurones ont persisté, malgré qu'ils aient adopté diverses formes et se soient dissimulés dans d'autres champs d'étude, comme le traitement adaptatif des signaux, l'analyse des motifs, la simulation en neurobiologie, et ainsi de suite. Des chercheurs éminents ont joué un rôle actif durant cette période, parmi lesquels on peut citer des personnalités notables telles que S. Grossberg et T. Kohonen, que nous aborderons de manière plus approfondie ultérieurement.

### **Le renouveau**

- En 1982, J. J. Hopfield, un physicien de renom, a joué un rôle déterminant dans le regain d'intérêt pour les réseaux de neurones artificiels, et ce, pour plusieurs raisons substantielles. À travers un article concis, clair et bien rédigé, il a présenté une théorie sur le fonctionnement et les possibilités des réseaux de neurones d'une manière peu conventionnelle. Alors que la plupart des auteurs s'attachaient jusqu'à présent à élaborer d'abord une structure et une règle d'apprentissage pour ensuite explorer les propriétés émergentes, J. J. Hopfield a adopté une approche inverse. Il a d'abord défini le comportement souhaité pour son modèle, puis a construit la structure et la règle d'apprentissage correspondant à ce résultat attendu. Son modèle est encore largement utilisé de nos jours pour résoudre des problèmes d'optimisation.

De plus, grâce à la renommée de ce physicien éminent, la théorie des réseaux de neurones a acquis une légitimité et a cessé d'être exclusivement l'affaire de psychologues et de neurobiologistes. Enfin, une petite observation subtile dans son article initial a mis en

lumière l'isomorphisme de son modèle avec le modèle d'Ising (modèle des verres de spins), ce qui a suscité l'intérêt des physiciens pour les réseaux de neurones artificiels.

À cette époque, le domaine de l'intelligence artificielle traversait une période de désillusion, car il n'avait pas comblé toutes les attentes et se heurtait à des limitations significatives. Bien que le modèle d'Hopfield n'ait pas résolu les limitations du Perceptron mises en évidence par M. Minsky, il a ravivé l'intérêt pour la recherche dans ce domaine.[8]

### **La levée des limitations**

- En 1983, la Machine de Boltzmann est apparue comme le tout premier modèle connu capable de résoudre de manière satisfaisante les limitations qui avaient été identifiées dans le cas du perceptron. Cependant, sa mise en pratique s'est avérée ardue en raison de la convergence extrêmement lente de l'algorithme, ce qui signifiait que les temps de calcul étaient considérablement longs.[9]
- En 1985, l'algorithme de rétropropagation de gradient a été introduit. Cet algorithme d'apprentissage était spécialement adapté aux réseaux de neurones multicouches, également connus sous le nom de Perceptrons multicouches. Sa découverte a été réalisée par trois groupes de chercheurs indépendants, soulignant ainsi que cette avancée était attendue depuis un certain temps. Dès sa découverte, il est devenu possible de réaliser des fonctions d'entrée/sortie non linéaires en décomposant cette fonction en une série d'étapes linéairement séparables. De nos jours, les réseaux multicouches et l'algorithme de rétropropagation de gradient demeurent les modèles les plus étudiés et les plus productifs en termes d'applications, et nous leur consacrerons plusieurs chapitres.[10]

### **La situation actuelle**

- En France, l'intérêt pour les réseaux de neurones est illustré par des événements tels que le congrès Neuro-Nîmes, qui se consacre aux réseaux neuromimétiques et à leurs applications. Ce congrès a été créé en 1988, et le nombre de participants augmente chaque année, reflétant l'intérêt croissant de la communauté scientifique et industrielle (50% des participants) pour le domaine de la connexionnisme. Voici un aperçu du développement des réseaux de neurones en France depuis 1992 jusqu'à nos jours.

### **Renaissance de l'apprentissage profond (2000) :**

## Chapitre II Réseaux De Neurones Artificiels

- Pendant cette période, d'importants progrès ont été réalisés dans le domaine de l'apprentissage profond. Les réseaux de neurones profonds à plusieurs couches ont été l'objet d'études approfondies et ont démontré des performances accrues dans la résolution de problèmes complexes. Parmi les travaux notables, on peut citer :

"A Fast Learning Algorithm for Deep Belief Nets" par Geoffrey Hinton, Simon Osindero et Yee-Whye Teh (2006) : Cette publication a présenté un algorithme efficace pour l'entraînement de réseaux de neurones profonds appelés "Deep Belief Nets".

Ces avancées ont ouvert la voie à de nouvelles opportunités dans le domaine de l'apprentissage automatique et ont contribué à l'essor du deeplearning..[11]

"Greedy Layer-Wise Training of Deep Networks" par Yoshua Bengio, Pascal Lamblin, Dan Popovici et Hugo Larochelle (2007) : Cette publication a proposé une méthode d'entraînement en couches successives pour les réseaux de neurones profonds.

### **Succès du Deep Learning (2010) :**

- Cette décennie a été marquée par des avancées majeures dans le domaine du deeplearning, avec des performances remarquables dans de nombreuses applications. Quelques développements notables comprennent :
  - "ImageNet Classification with Deep Convolutional Neural Networks" par Alex Krizhevsky, Ilya Sutskever et Geoffrey Hinton (2012) : Cette publication a introduit le célèbre modèle de réseau de neurones convolutifs appelé "AlexNet", qui a remporté le concours ImageNet en 2012.
  - "Deep Residual Learning for Image Recognition" par Kaiming He, Xiangyu Zhang, Shaoqing Ren et Jian Sun (2016) : Cette publication a présenté les réseaux de neurones résiduels (ResNet) qui ont surpassé les performances des réseaux de neurones profonds précédents dans la classification d'images.

Ces avancées ont considérablement amélioré la capacité des réseaux de neurones à effectuer des tâches complexes de vision par ordinateur, de traitement du langage naturel et d'autres domaines, ouvrant ainsi la voie à des applications innovantes dans de nombreux secteurs.

### **Exploration de nouvelles architectures et techniques (années 2010 - aujourd'hui):**

## **Chapitre II Réseaux De Neurones Artificiels**

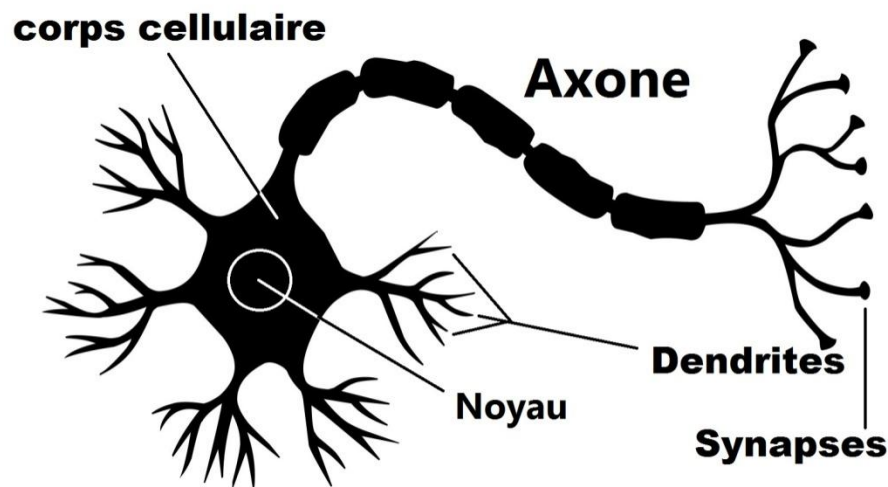
- Durant les récentes années, les investigations portant sur les réseaux de neurones s'est concentrée sur de nouvelles architectures et techniques pour améliorer les performances et résoudre des problèmes spécifiques. Quelques développements clés sont :
  - "Generative Adversarial Networks" par Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville et Yoshua Bengio (2014) : Cette publication a introduit les réseaux génératifs adversaires (GAN) qui ont permis de générer de nouvelles données réalistes.
  - "Attention Is All You Need" par Vaswani et al. (2017) : Cette publication a présenté le modèle de réseau de neurones Transformer, qui a révolutionné le domaine du traitement du langage naturel en utilisant exclusivement des mécanismes d'attention.

Ces développements ont ouvert de nouvelles opportunités dans le champ de l'apprentissage automatique, entraînant des avancées notables dans des domaines comme la création de contenu, la traduction automatisée, et la compréhension du langage naturel

### **II.3. Le neurone biologique**

Le neurone est fondamental dans l'architecture du système nerveux, constituant l'unité de base de son organisation. Ces entités hautement spécialisées exercent une fonction cruciale en ce qui concerne le traitement des signaux électriques et la transmission des messages nerveux. Dans l'enceinte du cerveau humain, le corps central de la cellule neuronale, logeant le noyau

cellulaire, présente une dimension d'approximativement quelques micromètres de diamètre. C'est précisément en ce lieu que réside l'influx nerveux, reflétant l'état d'activité du neurone.



**Figure 7: Le neurone biologique (œuvre d'artiste)**

- Les Les dendrites, les axones et les synapses sont des composantes cruciales de la structure et du fonctionnement des neurones. Les dendrites, qui constituent les principales entrées du neurone, sont responsables de la captation des signaux qui leur sont envoyés. Elles sont relativement courtes, mesurant quelques dizaines de micromètres.
- L'axone, en revanche, représente la sortie du neurone et transmet L'influx nerveux, sous la forme de potentiels d'action, est transmis aux neurones subséquents. Il se prolonge jusqu'à ces neurones, se ramifie à son extrémité, et peut varier considérablement en longueur, s'étendant sur des distances allant de quelques millimètres à plusieurs mètres.
- Les synapses jouent un rôle central dans le système nerveux en tant que jonctions entre deux neurones. Elles sont essentielles pour la transmission de signaux électriques et chimiques d'un neurone à un autre, permettant ainsi la communication et la coordination des activités neuronales.[12]

### **II.3.1. Fonctionnement du neurone biologique**

Le processus de transmission de l'information au sein du système nerveux s'effectue de manière unidirectionnelle, c'est-à-dire des dendrites aux axones. Chaque neurone reçoit des informations sous forme de signaux électriques provenant d'autres neurones par le biais de ses

dendrites. Si la somme de ces signaux est excitatrice, le neurone réagit en émettant à son tour un signal électrique qui se propage le long de ses axones. Ce signal est ensuite transmis aux terminaisons synaptiques, puis aux dendrites d'autres neurones.

La théorie de Hebb avance que l'apprentissage des neurones survient grâce à des modifications des résistances électriques au niveau des connexions dendrites. En d'autres termes, lorsque deux neurones sont activés simultanément de manière répétée, leur connexion mutuelle se renforce, facilitant ainsi la transmission future de signaux entre ces neurones. Cette notion est fondamentale pour comprendre la plasticité synaptique, un mécanisme essentiel de l'apprentissage et de la mémorisation dans le système nerveux.

### **II.4. Le neurone artificiel**

Un neurone artificiel, l'unité de base d'un réseau de neurones, agit de manière similaire à un neurone biologique en termes de traitement de l'information. Il est connecté à diverses sources d'information en entrée, telles que d'autres neurones, et génère une sortie en fonction de ces entrées.

Plus précisément, un neurone artificiel reçoit des données d'entrée numériques notées  $x_i$ , où  $i$  varie de 1 à  $N$ , avec  $N$  représentant le nombre total de données que le neurone reçoit. Chaque donnée d'entrée est associée à un coefficient  $w_i$  qui lui est propre, indiquant son importance relative pour le neurone.

Le neurone artificiel effectue ensuite une somme pondérée de ses données d'entrée, en multipliant chaque donnée  $x_i$  par son coefficient correspondant  $w_i$  et en ajoutant un terme de biais  $w_0$ . Ce terme de biais, également appelé biais, est souvent associé à une donnée d'entrée fictive  $x_0$  qui est fixée à  $-1$ . La somme pondérée est ensuite soumise à une fonction d'activation, qui détermine la sortie finale du neurone en fonction du résultat de cette opération.

Ce processus de somme pondérée et d'activation se produit pour chaque neurone dans un réseau de neurones, et c'est ainsi que les réseaux de neurones modélisent la manière dont les neurones biologiques traitent l'information pour effectuer des tâches complexes d'apprentissage et de prise de décision.

$$S = w_1 \times x_1 + \dots + w_N \times x_N - w_0 = \sum_{i=1}^N w_i \times x_i - w_0$$

Tout à fait, la fonction d'activation joue un rôle crucial dans la modélisation du comportement des neurones artificiels. Elle est responsable de l'adaptation de la valeur de la somme pondérée des entrées aux caractéristiques souhaitées de la sortie du neurone.


En effet, la fonction d'activation permet de transformer la sortie potentielle d'un neurone en une forme qui convient à la tâche spécifique à laquelle le réseau de neurones est destiné. Elle agit comme un filtre, en renvoyant généralement une valeur proche de 1 lorsque les "bonnes" informations d'entrée sont présentes, et une valeur proche de 0 lorsque les informations sont "mauvaises".

Il existe diverses fonctions d'activation employées dans les réseaux de neurones., chacune ayant ses propres propriétés et applications. Par exemple, la fonction d'activation sigmoïde est couramment utilisée, car elle produit des sorties dans l'intervalle [0, 1], ce qui est utile pour modéliser des probabilités ou des décisions binaires. D'autres fonctions d'activation populaires incluent la fonction ReLU (RectifiedLinear Unit) et la fonction tangente hyperbolique (tanh), qui ont des comportements différents et sont adaptées à différentes situations d'apprentissage.

La sélection de la fonction d'activation dépend de la nature de la tâche que le réseau de neurones doit accomplir, et il peut avoir un impact significatif sur la capacité du réseau à apprendre et à généraliser à partir des données d'entrée.

$$y = f\left(\sum_{i=0}^N w_i \times x_i - w_0\right)$$





**Figure 8: la composition d'un neurone artificiel**

La figure illustre qu'un neurone artificiel est composé de trois éléments fondamentaux:

- Un réseau de liaisons connecté aux différentes entrées  $X_n$ , chaque liaison étant associée à un poids spécifique  $W_n$ .
- Un dispositif d'addition permettant de calculer une somme pondérée des entrées  $X_n$  pondérées par les coefficients,
- Un terme de biais  $w_0$  utilisé pour réguler l'entrée de la fonction d'activation

Une fonction d'activation  $f$  qui détermine la valeur de sortie  $y$  du neurone. [13]


#### **II.4.1. fonction d'activation :**

Dans les Réseaux Neuronaux Artificiels (RNA), différentes fonctions de transfert peuvent être utilisées comme fonctions d'activation. Parmi celles-ci, les fonctions "seuil" (ou "hard limit" en anglais) sont largement utilisées.

La fonction de seuillage applique un seuil à son entrée. Si l'entrée est négative, elle ne dépasse pas le seuil et la fonction renvoie la valeur « 0 », ce qui peut être interprété comme "faux" de manière significative. En revanche, si l'entrée est positive ou égale au seuil, elle excède le seuil et la fonction renvoie la valeur « 1 », ce qui peut être interprété comme "vrai". Cette fonction est couramment employée dans le cadre d'un neurone. pour prendre des décisions binaires.

Dans l'expression mathématique  $y = \text{hard limit}(w^T x - b)$ , le biais  $b$  joue un rôle important. Il définit la position du seuil sur l'axe  $w^T x$ , où la fonction bascule de « 0 » à « 1 ».

Ainsi, le biais permet de régler le seuil de décision et d'influencer les décisions binaires prises par le neurone.



**Figure 9 : (a) Fonctions d'activations « seuil » ; (b) Fonctions d'activations « linéaire », (c) Fonctions d'activations « sigmoïde ».**

Effectivement, La fonction linéaire est très basique, elle attribue directement sa valeur d'entrée à sa sortie. Mathématiquement, elle est représentée par l'équation  $y = x$ . Dans le cadre d'un neurone, cette fonction est représentée. dans la Figure II.10 (b) La sortie du neurone reflète son degré d'activation, et elle reste constante à partir de zéro tant que la somme pondérée des entrées,  $w^T x$ , est différente de la valeur du biais  $b$ .

La fonction de transfert sigmoïde, illustrée dans la Figure II.10 (c), est définie par l'équation

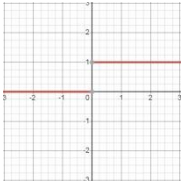
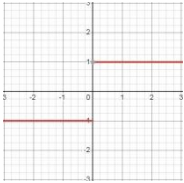
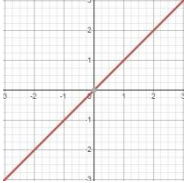
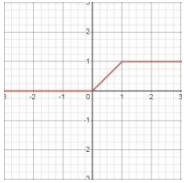
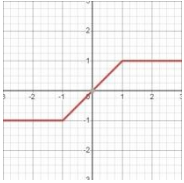
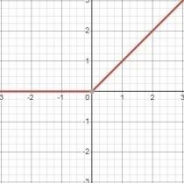
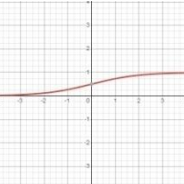
$$y = \frac{1}{(1 + \exp(-x))}$$

Cette fonction présente des similitudes avec la fonction seuil et linéaire en fonction de la distance entre la valeur  $w^T x$  et le biais  $b$ . Lorsque  $w^T x$  est éloigné de  $b$ , la fonction sigmoïde ressemble à la fonction seuil avec une discontinuité, tandis que lorsque  $w^T x$  est proche de  $b$ , elle ressemble à la fonction linéaire avec un changement de pente doux. Ainsi, La fonction sigmoïde constitue une solution équilibrée entre les deux fonctions..

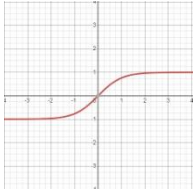
Il convient également de noter la fonction "tangente hyperbolique (tanh)" représente une variante symétrique de la sigmoïde. Elle a une plage de valeurs de « -1 » à « 1 » et est souvent utilisée dans les réseaux neuronaux pour introduire une non-linéarité symétrique.

**II.4.1.1. Différentes fonctions d'activations utilisées dans les RNA**

**Tableau 1: Différentes fonctions d'activations utilisées dans les RNA**

<i>Nom de la fonction</i>	<i>Relation Entrée(x)/sortie(y)</i>	<i>Nom sur MATLAB</i>	<i>Graphe</i>
Seuil	$f = 0$ si $x < 0$ $f = 1$ si $x \geq 0$	hardlim	
Seuil symétrique	$f = -1$ si $x < 0$ $f = 0$ si $x \geq 0$	hardlims	
Linéaire	$f = x$	purelin	
Linéaire saturée	$f = 0$ si $x \leq 0$ $f = x$ si $0 \leq x \leq 1$ $f = 1$ si $x \geq 1$	satlin	
Linéaire saturée symétrique	$f = -1$ si $x < -1$ $f = x$ si $-1 \leq x \leq 1$ $f = 1$ si $x > 1$	satlins	
Linéaire positive	$f = 0$ si $x \leq 0$ $f = x$ si $x \geq 0$	poslin	
Sigmoïde	$f = \frac{1}{1 + \exp^{-x}}$	logsig	

---

Tangente hyperbolique	$f = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	tansig	
Compétitive	$f = 1$ si $x$ maximum $f = 0$ autrement	compet	<div style="border: 2px solid red; padding: 5px; display: inline-block;"><b>C</b></div>

---

## II.5. L'architecture de réseau de neurones artificiels

Un réseau de neurones artificiel est en effet défini par son architecture, qui spécifie la structure de ses neurones, leur connectivité et la manière dont ils sont organisés. L'une des structures des réseaux de neurones les plus courantes est basée sur des couches de neurones interconnectés, appelée réseau de neurones multicouches. Cette architecture est largement utilisée dans de nombreuses utilisations dans le monde des affaires et de l'industrie. en raison de sa capacité à représenter de manière mathématique les relations complexes entre les entrées et les sorties.

Cependant, le texte mentionne également le réseau de neurones monocouche, connu sous le nom de perceptron. Voici une brève description de cette architecture :

### II.5.1. Réseau de neurone monocouche (Perceptron) :


Le perceptron représente une forme élémentaire de réseau de neurones artificiel composé d'une seule couche de neurones. Chaque unité neuronale dans cette couche est reliée à toutes les entrées, Cependant, il n'existe aucune connexion directe entre les neurones au sein de la couche. Chaque connexion entre une entrée et un neurone est associée à un poids.

Le fonctionnement du perceptron est relativement simple. Chaque neurone calcule une somme pondérée des signaux d'entrée. en utilisant les poids associés, puis applique une fonction d'activation pour produire une sortie. Cette sortie peut être employée pour prendre des décisions binaires, par exemple, pour la classification binaire.

Le perceptron a des limitations et ne peut pas modéliser des relations non linéaires complexes. Cependant, il a posé les bases des réseaux de neurones plus avancés, notamment les réseaux de neurones multicouches, qui sont capables d'apprendre des fonctions non linéaires plus complexes.

## Chapitre II Réseaux De Neurones Artificiels

Les réseaux de neurones multicouches, avec leurs couches d'entrée, cachées et de sortie, sont en mesure de résoudre des problèmes bien plus complexes en utilisant des fonctions d'activation non linéaires, et c'est pourquoi ils trouvent une large utilisation dans diverses applications. modernes d'apprentissage automatique et de deeplearning.



**Figure 10: Exemple d'un réseau de neurones.**

Le réseau de neurones est conçu avec  $N$  données d'entrée et  $P$  sorties., où chaque neurone de la couche de sortie est associée à une catégorie particulière. Lorsqu'un exemple  $X$  est présenté au réseau, chaque neurone de la couche de sortie calcule sa sortie. Une utilisation typique de ce modèle est de considérer que chaque unité neuronale dans la couche de sortie. représente une classe particulière. Par conséquent, pour un exemple donné  $X$ , la classe attribuée à cet exemple est généralement celle qui correspond à l'unité de sortie avec la valeur de sortie la plus élevée .


Pour résumer, le réseau de neurones effectue une classification en attribuant à l'exemple d'entrée  $X$  la classe liée à l'unité de sortie ayant l'activation la plus élevée.. Cette approche est couramment utilisée dans les problèmes de classification, où l'objectif est de catégoriser des entrées dans diverses classes ou catégories en fonction de leurs attributs distinctifs.

### **II.5.2. Réseau de neurone multicouche**

Au sein de cette architecture, les neurones de la première couche sont. directement connectés à toutes les informations d'entrée. Ensuite, les neurones de la deuxième couche reçoit toutes les sorties générées par les neurones de la première couche.. Ce schéma se poursuit de manière récursive pour les couches suivantes jusqu'à ce que l'on atteigne la couche

de sortie, où le neurone de sortie final reçoit les sorties des neurones de la dernière couche cachée.

Cette structure en couches et en connexion séquentielle est caractéristique des réseaux de neurones multicouches (ou perceptrons multicouches). Chaque couche intermédiaire peut être considérée comme une transformation non linéaire des entrées, Cela permet au réseau d'acquérir des connaissances des caractéristiques de plus en plus abstraites et complexes à mesure que l'on avance vers les couches de sortie. Cette hiérarchie de couches intermédiaires est ce qui rend les réseaux de neurones profonds (deeplearning) efficaces pour la modélisation de données complexes et la résolution de tâches d'apprentissage automatique..[13]



**Figure 11: Schéma d'un perceptron Multicouche**

Les couches 1 et 2 sont souvent désignées comme des couches cachées, tandis que la couche 3 est la couche de sortie.

### **II.6. Apprentissage des RNA**

Les réseaux de neurones artificiels sont principalement employés pour des missions d'apprentissage, en particulier pour la classification. Ce processus d'apprentissage implique une adaptation itérative des poids  $W_i$  du réseau de manière à obtenir la meilleure fonction possible, qui satisfait l'équation  $f(x_i) = y_i$  pour tous les exemples d'apprentissage, où  $i$  varie de 1 à  $N$ . Initialement, les valeurs des poids  $W_i$  sont généralement initialisées de manière aléatoire, puis elles sont corrigées en fonction des erreurs entre les sorties  $y_i$  générées par le réseau et les sorties souhaitées.

## Chapitre II Réseaux De Neurones Artificiels

Au sein d'un réseau de neurones à plusieurs couches, ce processus de correction des poids se déroule en sens inverse du flux de données, ce qui est couramment appelé "backpropagation". Lors de la présentation de chaque Un exemple d'apprentissage pour le réseau, deux étapes distinctes sont effectuées :

Propagation avant (Forward Propagation) : Les valeurs du vecteur d'entrée, représentant l'exemple, sont introduites dans la couche initiale du réseau. Ces données se diffusent ensuite de couche en couche, du début du réseau jusqu'à la couche de sortie, en transitant par toutes les couches intermédiaires.

Chaque neurone calcule une somme pondérée des signaux d'entrée, puis applique une fonction d'activation , puis transmet le résultat à destination des neurones de la couche suivante Cette phase aboutit à l'obtention d'un vecteur de sortie  $y_i$ .

Backpropagation : Une fois que le réseau a généré ses sorties pour un exemple donné, les erreurs entre ces sorties ( $y_i$ ) et les sorties attendues sont calculées. Ensuite, ces erreurs sont propagées en sens inverse à travers le réseau, de la couche de sortie à la couche d'entrée. Pendant cette étape, les poids  $W_i$  de toutes les connexions entre les neurones sont ajustés afin de minimiser la différence entre les sorties réelles et les sorties attendues. La correction se fait en appliquant des techniques d'optimisation, comme la descente de gradient..

Ces deux étapes de propagation avant et de backpropagation sont répétées pour chaque exemple d'apprentissage présenté au réseau. Ce processus itératif permet au réseau de s'ajuster progressivement aux données d'apprentissage et d'apprendre à effectuer correctement la classification ou la tâche souhaitée. Une fois le réseau de neurones artificiels correctement entraîné, il peut être utilisé pour classer de nouveaux exemples en injectant leurs valeurs dans l'entrée du réseau et en recevant la classe correspondante en sortie par propagation avant..[13]

L'apprentissage par descente de gradient avec l'erreur quadratique est une méthode couramment utilisée pour l'entraînement de perceptrons monocouches. Voici l'algorithme de cette méthode :

---

### **Algorithme 4** Apprentissage RNA par décente de gradient

---

- 1: Créer n variables  $\partial w_i$ , pour  $1 \leq i \leq n$  , égales à 0
- 2: Prendre un exemple  $e_k$ , pour  $1 \leq k \leq N$
- 3: Déterminer la valeur de sortie obtenue avec les poids actuels, désignée par  $s_k$

## Chapitre II Réseaux De Neurones Artificiels

4: Rajouter à  $d w_i$ , pour tout  $1 \leq i \leq n$ , le nombre  $\alpha(y_k - s_k)x_i$

5: Répéter les étapes (3) et (4) pour chaque exemple.

6: pour  $1 \leq i \leq n$ , remplacer  $w_i$  par  $w_i + \partial w_i$

---

Le paramètre  $\alpha$ , également connu sous le nom de taux (ou vitesse) d'apprentissage, nécessite une sélection minutieuse. Un  $\alpha$  trop élevé peut entraîner des oscillations du réseau autour d'un minimum local, tandis qu'un  $\alpha$  trop faible augmente le nombre d'itérations nécessaires. En pratique, il est courant de réduire progressivement la valeur de  $\alpha$  au fur et à mesure des itérations.

Pour obtenir des résultats satisfaisants, il est nécessaire de présenter plusieurs fois les exemples à chaque neurone, ce qui permet aux poids de converger vers des valeurs "idéales".

Cependant, cette méthode a l'inconvénient de corriger les poids en fonction de l'ensemble global des exemples, ce qui signifie que le réseau ne commence à s'ajuster aux exemples qu'après un certain laps de temps. Une autre approche, appelée méthode d'apprentissage de Widrow-Hoff, permet de corriger les poids pour chaque exemple individuellement.

---

### **Algorithme 5** Apprentissage RNA par Widrow-Hoff

---

**Entrée :**

–  $n$  poids reliant les  $n$  informations données à notre neurone possédant des valeurs arbitraires

–  $N$  exemples  $(X_k, y_k)$  où  $X_k$  est un vecteur à  $n$  composantes  $x_i$ , chacune d'entre elles symbolisant une caractéristique de cet exemple.

– Le taux d'apprentissage  $\alpha$

**Sortie :** les  $n$  poids modifiés

**pour** Tout exemple =  $(X_k, y_k)$  **faire**

    Calculer la sortie  $s_k$  du neurone

**pour**  $1 \leq i \leq n$  **faire**

$$w_i = w_i + \alpha(y_k - s_k)x_i$$

**fin pour**



*fin pour*

---

Cette technique est couramment étendue pour le perfectionnement d'un réseau de neurones à plusieurs couches. L'algorithme suivant expose la démarche d'entraînement d'un réseau de neurones à plusieurs couches.

---

### **Algorithme 6** Apprentissage RNA multicouche

---

Initialiser aléatoirement les coefficients  $w_{ij}$  dans  $[-0.5 ; 0.5]$

**Répéter**

Prendre un exemple  $(x, y)$

Calculer la sortie  $s$

**pour** toute cellule de sortie **ifaire**

$$\delta_i = s_i \times (1 - s_i) \times (y_i - s_i)$$

**fin pour**

**pour** chaque couche de  $q - 1$  à 1 **faire**

**pour** chaque cellule  $i$  de la couche courante **faire**

$$\delta_i = s_i \times (1 - s_i) \times \left[ \sum_{(k \in Succ(i))} (\delta_k \times w_{ki}) \right]$$

**fin pour**

**fin pour**

**pour** Pour tout poids  $w_{ij}$  **faire**

$$w_{ij} = w_{ij} + \alpha \times \delta_i \times X_{ij}$$

**fin pour**

**Fin Répéter.**

---

## **II.7. revue bibliographique sur les réseaux de neurones**

Cette section met en lumière les recherches expérimentales et numériques existantes dans la littérature concernant les principales caractéristiques des nanofluides et leur impact sur le transfert de chaleur. Ces caractéristiques englobent la conductivité thermique, la capacité thermique et la viscosité dynamique. Plusieurs relations ont été proposées et comparées aux équations classiques.

## Chapitre II Réseaux De Neurones Artificiels

- McCulloch & Pitts (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.

Ce travail est considéré comme l'un des pionniers dans le domaine des réseaux de neurones. McCulloch et Pitts ont élaboré un modèle mathématique abstrait pour décrire le comportement des neurones biologiques.

- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408.

Cette étude marque le développement du perceptron, un type spécifique de réseau de neurones à une seule couche, capable d'apprendre à classifier des données. Elle a été l'une des premières à explorer les applications pratiques des réseaux de neurones.

- Rumelhart, Hinton, & Williams (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.

Cet article emblématique a introduit et popularisé la technique de rétropropagation du gradient, permettant l'apprentissage efficace des réseaux de neurones multicouches. Il a contribué à un regain d'intérêt pour les réseaux de neurones dans les années 1980.

- LeCun, Bengio, & Hinton (2015). Deep learning. *Nature*, 521(7553), 436-444.

Cette publication met en avant l'apprentissage profond (deep learning) et son impact significatif dans le domaine de l'intelligence artificielle. Elle a catalysé l'évolution des réseaux de neurones et leur utilisation dans diverses applications.

Cette revue couvre l'évolution des réseaux de neurones vers l'apprentissage profond (deep learning). Elle présente les architectures profondes, telles que les réseaux de neurones convolutionnels et récurrents, ainsi que leurs applications dans des domaines tels que la vision par ordinateur et le traitement du langage naturel.

- Goodfellow, Bengio, & Courville, A (2016). *Deep Learning*. MIT Press.

Ce livre exhaustif fournit une couverture complète de l'apprentissage profond, en expliquant les concepts clés des réseaux de neurones et en détaillant les architectures et les techniques d'apprentissage utilisées. Il comprend également des études de cas et des applications concrètes.

Ces références constituent un point de départ solide pour explorer l'histoire et le développement des réseaux de neurones. Elles illustrent les contributions importantes de

## **Chapitre II Réseaux De Neurones Artificiels**

différents chercheurs et mettent en évidence les étapes clés dans l'évolution des réseaux de neurones.

### **Conclusion**

Les réseaux de neurones artificiels ont profondément transformé le domaine de la reconnaissance de motifs et de la prise de décision. Ils ont puisé leur inspiration dans le fonctionnement du cerveau humain et sont composés d'un grand nombre de nœuds interconnectés. Chaque nœud est en mesure de prendre des choix, d'apprendre et de s'adapter.

Les réseaux de neurones artificiels sont employés dans de multiples domaines, notamment dans la reconnaissance de la parole, la détection de fraude, la classification d'images, la prédiction des prix de l'immobilier et la recommandation de produits. Ils sont également utilisés dans les voitures autonomes pour reconnaître les panneaux de signalisation et les piétons.

Cependant, les réseaux de neurones artificiels présentent également des défis tels que la difficulté à interpréter les décisions prises par les réseaux, la nécessité de données massives pour l'apprentissage et la complexité de la configuration. Les progrès continus de l'apprentissage profond ont permis d'atténuer certains de ces problèmes.

En définitive, les réseaux de neurones artificiels sont une technologie passionnante et en constante évolution qui a le potentiel de transformer radicalement la façon dont nous interagissons avec le monde numérique et physique.



### Références

- [1] Haykin, S. (1998). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- [2] James, W. (1890). *Habit*. H. Holt.
- [3] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- [4] Hebb, D. O. (1949). *The organization of behavior: A neuropsychological theory*. Science editions.
- [5] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- [6] Hoff, M. E., & Widrow, B. (1960, August). Adaptive switching circuits. In 1960 IRE WESCON Convention Recor (pp. 96-104).
- [7] Minsky, M. L., & Papert, S. A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press.
- [8] 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.
- [9] Hinton, G. E., & Sejnowski, T. J. (1983, June). Optimal perceptual inference. In *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition* (Vol. 448, pp. 448-453).
- [10] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- [11] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [12] Djeriri, Y., Boudjema, Z. (2017). *Commande robuste par la logique floue et les réseaux de neurones artificiels de la GADA : étude comparative*. *Revue des Energies Renouvelables*, 20(1), 147-160.
- [13] Brakni, E. M. (2011). *Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM*, Doctoral dissertation, Université du Québec en Abitibi-Témiscamingue, Canada.

## **Chapitre II Réseaux De Neurons Artificiels**

[14] Baghli, L. (1999). Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques'', Doctoral dissertation, Henri Poincaré Nancy-I, France

# ***CHAPITRE III***

## **Chapitre III Résultat et discussion**

### **Introduction :**

Comme nous l'avons exploré précédemment, il existe plusieurs facteurs qui peuvent influencer l'efficacité des nanofluides, tels que la concentration, le type et la forme des nanoparticules, les caractéristiques du fluide de base, la température, et autres. De nombreuses études se sont concentrées sur ces propriétés des nanofluides, en se concentrant spécifiquement sur l'influence de la viscosité dynamique et de la conductivité thermique[1].

Dans le domaine des nanotechnologies, de nombreuses recherches ont été menées par des scientifiques pour étudier les propriétés thermophysiques des nanomatériaux. Des analyses expérimentales, ainsi que des études théoriques approfondies ont été réalisées afin de mieux comprendre ces propriétés. Les chercheurs attachent une grande importance à la température et à la fraction volumique en tant que facteurs clés lors du développement de modèles de calcul pour estimer des caractéristiques thermophysiques comme la conductivité thermique. et la viscosité .

Lorsque la température augmente, cela entraîne une élévation de la capacité de conduction thermique. et une réduction de la viscosité dynamique dans les nanofluides. De même, une concentration plus élevée de particules solides entraîne à la fois une élévation de la capacité de conduction thermique et de la viscosité dynamique.

Dans l'état actuel de la recherche, la plupart des modèles disponibles sont applicables aux nanofluides présentant une concentration relativement faible de nanoparticules, généralement comprise entre 0,01% et 0,5% en volume, et une dispersion uniforme de ces particules. Toutefois, ces modèles ne prennent pas en considération la relation entre les propriétés thermophysiques et la forme des nanoparticules. De plus, la mesure expérimentale des propriétés thermophysiques des nanofluides pour des combinaisons spécifiques de température, de concentration, de taille et de forme nécessite des ressources considérables en termes de temps, de données et de coûts.

Pour surmonter ces difficultés, de nombreux chercheurs ont proposé différentes approches de modélisation ou des modèles empiriques pour prédire les propriétés thermophysiques de ces nanofluides. Parmi ces approches, l'emploi de méthodes d'apprentissage automatique comme les réseaux de neurones artificiels(RNA) s'est avérée être une méthode simple et efficace pour déterminer ces propriétés pour différents types de nanofluides [16].



### **Chapitre III Résultat et discussion**

Par conséquent, dans ce chapitre, nous utilisons une approche de modélisation basée sur la méthode des Réseaux Neuronaux Artificiels (RNA) pour prédire et évaluer la conductivité thermique effective et la viscosité dynamique desnanofluides à base de ('Al<sub>2</sub>O<sub>3</sub>/Eau,Cuo/Eau...ect).

Cette approche nous permettra de développer un modèle prédictif fiable en utilisant les données expérimentales disponibles. Grâce aux Réseaux Neuronaux Artificiels, nous pourrons capturer les relations complexes entre les paramètres clés tels que la concentration en nanoparticules, la température et les propriétés thermophysiques des nanofluides.




L'objectif consiste à acquérir une compréhension plus approfondie du comportement des nanofluides('Al<sub>2</sub>O<sub>3</sub>/Eau,Cuo/Eau...ect) et de prédire avec précision leurs propriétés thermophysiques. Cela pourrait permettre d'optimiser leur utilisation dans diverses applications liées au transfert de chaleur et à la dissipation thermique.

#### **III.1. Matériels et méthodes :**

##### **Outils informatique utilisée :**

Voici le (*tableau 2*) répertoriant les logiciels utilisés dans ce travail :

**Tableau 2 : Logiciels utilisés**

Logiciel	Logo	Version
Mecrosoft office Excel		2020
WebPlotDigitizer		4.6
Matlab		2010

## **Chapitre III Résultat et discussion**

Il est important de mentionner que tous les calculs réalisés dans le cadre de ce travail ont été effectués à l'aide d'ordinateurs personnels :

- DELL : processeur i3 ; 4 Go de RMA; Windows 7
- HP :processeur celeron (R) CPU N3060 ; 4 Go de RMA ; Windows 10 Professional

### **III.2. Méthodologie de la modélisation neuronale :**

La démarche adoptée pour la modélisation neuronale au sein de ce projet tourne autour de de plusieurs phases, telles qu'illustré dans la Figure III.1 :

- Acquisition des données : Cette étape initiale consiste à rassembler la base de données nécessaire à l'analyse.
- Partitionnement de la base de données: La base de données collectée est ensuite divisée de manière appropriée, généralement en ensembles d'entraînement et de test, afin d'évaluer les résultats obtenus du modèle.
- Optimisation de l'architecture des réseaux de neurones artificiels (RNA) : On procède à l'optimisation des structures et des paramètres des RNA afin d'obtenir des modèles performants.
- Sélection du meilleur modèle : Parmi les modèles générés, celui qui offre les meilleures performances est sélectionné pour des analyses ultérieures.
- Analyse de sensibilité : Une analyse approfondie est menée pour évaluer la sensibilité du modèle aux différentes variables et paramètres, ce qui permet de mieux comprendre son comportement.

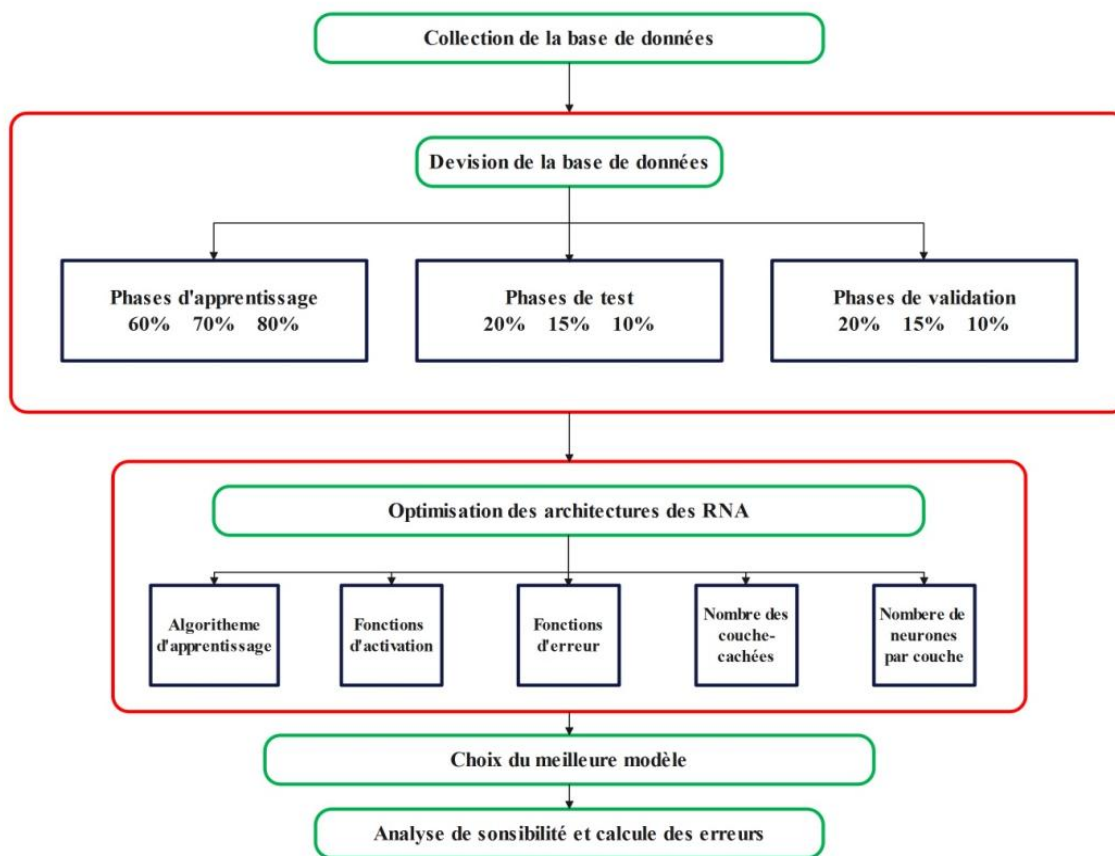


Figure 12 : La méthodologie employée pour la modélisation neuronale

### III.2.1. Collecte la base des données

L'aspect le plus difficile de la modélisation appliquée est de collecter des données précises à partir de diverses études expérimentales. Comme mentionné précédemment, la viscosité et la conductivité thermique d'un nanofluide dépend de la température, de la taille et la fraction volumique des nanoparticules, et de la viscosité et conductivité du fluide de base. Ainsi, pour assurer l'exactitude et la fiabilité du modèle proposé, nous avons collecté 2916 ensembles de données provenant de différentes études expérimentales (Tableau III.3). Dans la plupart des configurations pratiques, les techniques d'apprentissage automatique manquent de robustesse et échouent à fournir une prédiction précise en raison de l'utilisation de petits ensembles de données (jusqu'à quelques centaines de points de données). Par conséquent, il est essentiel de recourir à un ensemble de données important pour l'entraînement et le test du modèle actuel. Dans ce modèle, un total de 9000 points de données de viscosité de nanofluides à base d'eau, EG, PG, ... (nanoparticules  $Al_2O_3$ , CuO) sont inclus dans l'ensemble de données, sont extraits expérimentalement à partir de différentes études.

## **Chapitre III Résultat et discussion**

### **III.2.1.1. Choix des entrées et sorties**

Le choix des variables d'entrée revêt une grande importance dans la modélisation de grandeurs. Elle poursuit deux objectifs fondamentaux :

1. Réduire la dimension de l'espace où sont représentées les variables du modèle.
2. Éliminer les entrées ayant une influence négligeable ou faible sur la sortie.

Il est crucial de souligner que l'ajout de chaque variable engendre une complexité accrue du modèle et conduit à une augmentation du nombre de paramètres du réseau. C'est pourquoi il est essentiel d'incorporer dans l'inclusion de tous les facteurs pertinents dans la représentation des entrées, pour la variable que l'on souhaite modéliser.

Dans cette recherche, nous avons décidé de nous concentrer sur avec les variables d'entrée et de sortie présentées dans le (*tableau3*), en accord avec ces principes.

**Tableau 3: Énumération des paramètres des entrées et des sorties.**

<i>Variables</i>	<i>Propriétés</i>	
	<b>Conductivité</b>	<b>Viscosité</b>
<i>Entrés</i>	$T(k)$	$T(k)$
	$d_p(nm)$	$d_p(nm)$
	$\emptyset (\%)$	$\emptyset (\%)$
	$k_{fb}(W/mk)$	$\mu_{fb}(Mpas)$
<i>Sortie</i>	$k_{nf}(W/mk)$	$\mu_{nf}(Mpas)$

### **III.2.1.2. Un aperçu des données utilisées dans la modélisation :**

Les données expérimentales ont été extraites de 56 articles très cités différents. Le Tableau répertorie les articles qui ont servi de source pour la collecte de données expérimentales.

### Chapitre III Résultat et discussion

**Tableau 4 : documentation des données expérimentales**

Propriétés	nanoparticules	Document
Conductivité thermique	Al <sub>2</sub> O <sub>3</sub>	[1][2][3][4][5][6][7][8][9][10][11][12][13][14][15][16][17][18][19][20][21][22][23][24][25][26][27][28][29][30][31][32][33][34][35][36][37][38][39][40][41][42][43][44][45][46].
	CuO	[3][2][5][7][9][10][11][12][20][23][33][37][39][47].
Viscosity	Al <sub>2</sub> O <sub>3</sub>	[4][6][48][49][50][51][52][53]
	CuO	[54] [55] [56]

#### III.2.1.3. Spécifications détaillées de l'ensemble de données expérimentales :

**Tableau 5 : détaillées des données expérimentales**

##### *conductivité thermique :*

Nanoparticules	Al <sub>2</sub> O <sub>3</sub>	CuO
<i>Points de données</i>	1430	408
<i>Fraction volumique [%]</i>	0.01-18	0.01-14
<i>fluide de base [W/mk]</i>	0.14-0.6	0.25-0.68
<i>Taille [nm]</i>	5-282	20-40
<i>Température [K]</i>	14-116	14-97

##### *Viscosité :*

Nanoparticules	Al <sub>2</sub> O <sub>3</sub>	CuO
<i>Points de données</i>	701	377
<i>Fraction volumique [%]</i>	0.01 - 10	0.01 - 10
<i>fluide de base [MPa.s]</i>	0.40 - 97	0.40 - 97
<i>Taille [nm]</i>	20 - 29	20 - 29
<i>Température [K]</i>	-35 - 70	-35 - 70

#### III.2.2. Division de la base de données :

Dans cette étude, nous nous intéressons à la prédiction de deux propriétés clés des nanofluids, la viscosité et la conductivité. Pour mener à bien cette tâche, nous utilisons deux bases de données distinctes, l'une pour la viscosité et l'autre pour la conductivité. Afin

### **Chapitre III Résultat et discussion**

d'entraîner et d'évaluer nos modèles de prédiction, nous devons diviser ces bases de données en ensembles d'apprentissage, de test et de validation.

Pour la première division, nous avons opté pour une répartition de 70%, 15% et 15% respectivement pour les ensembles d'apprentissage, de test et de validation. Cela signifie que 70% des données de viscosité et de conductivité seront utilisées pour l'apprentissage de nos modèles, tandis que 15% seront réservées à l'évaluation des performances sur des données non vues pendant l'apprentissage, et les 15% restants serviront à valider et affiner les performances finales du modèle.

Deux autre répartition que nous avons envisagée : [80,10,10] et [60,20,20] ,respectivement pour les ensembles d'apprentissage, de test et de validation.

En divisant nos bases de données selon ces différentes proportions, nous sommes en mesure de développer et d'évaluer des modèles de prédiction précis pour la viscosité et la conductivité des nanofluids. Cette approche nous permet de garantir des résultats fiables et de haute qualité.

### **III.3. Optimisation des architectures des RNA :**

L'amélioration des structures des réseaux de neurones artificiels (RNA) de type (PMC) réseau de neurones multicouches a été réalisée en utilisant le logiciel "MATLAB", en suivant les étapes détaillées ci-dessous :

- **Choix de l'algorithme d'apprentissage** : L'algorithme Levenberg-Marquardt à propagation en arrière, plus spécifiquement le "Levenberg-Marquardt backpropagation" (trainlm), a été sélectionné pour guider l'apprentissage des réseaux.
- **Utilisation de trois fonctions d'activation différentes** : Ces fonctions d'activation ont été appliquées aussi bien à la couche cachée qu'à la couche de sortie, comme illustré dans la Figure III.2.
- **Sélection de la fonction d'erreur** : La fonction d'erreur "MeanAbsoluteAbsolute Relative Difference (MAARD)" a été choisie pour évaluer les performances et l'adéquation du modèle.
- **Variation du quantité de neurones présents dans la couche cachée.** : Le nombre de neurones dans cette couche a été systématiquement modifié, en explorant une plage allant de 10 à 30 neurones, afin de trouver la configuration optimale.

## Chapitre III Résultat et discussion




Figure 13 : les fonctions d'activation utiliser les fonctions d'activation utiliser

### III.3.1. Choix du meilleur modèle

La Sélection du modèle optimal repose sur l'évaluation de deux critères principaux : l'erreur de Mean Absolute Absolute Relative Difference (MAARD) et le coefficient de corrélation (R). Cette sélection est effectuée en suivant une approche de test et d'erreur, où l'objectif est de minimiser l'erreur MAARD, en la rapprochant autant que possible de zéro, tout en maximisant le coefficient de corrélation R, en l'approchant autant que possible de 1.

La capacité de prévision d'un modèle est généralement estimé à l'aide du Coefficient de corrélation R. Un R supérieur à 0,5 est habituellement jugé adéquat., indiquant une certaine capacité du modèle à capturer la relation entre les données en entrée et celles en sortie. Une valeur de R supérieure à 0.9 est considérée comme excellente, ce qui indique que le modèle présente une performance élevée dans la prédiction des résultats.

En résumé, le choix du meilleur modèle repose sur la quête d'un juste équilibre entre une faible erreur MAARD (proche de zéro) et un fort coefficient de corrélation R (proche de 1), ce qui indique un modèle robuste et précis dans la prédiction des résultats.

### III.3.2. Analyse des erreurs

L'analyse de l'erreur est une étape cruciale dans l'évaluation. de la précision des modèles de Réseaux Neuronaux Artificiels (RNA) employés pour anticiper les caractéristiques thermophysiques des nanofluides. Cette analyse permet de quantifier à quel point les prédictions du modèle correspondent aux valeurs réelles et d'identifier les domaines où le modèle peut présenter des lacunes. Voici les principales composantes de l'analyse de l'erreur pour ces modèles :

$$MAARD = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i^{exp} - y_i^{cal}}{y_i^{exp}} \right|$$

### Chapitre III Résultat et discussion

$$REQM = \sqrt{\sum_{i=1}^N (y_i^{exp} - y_i^{cal})^2 / N}$$

$$ERM = \left(\frac{100}{N}\right) * \sum_{i=1}^N (|y_i^{exp} - y_i^{cal}| / y_i^{cal})$$

$$R = \frac{\sum_i [(y_i^{exp} - \hat{y}^{cal})(y_i^{cal} - \hat{y}^{cal})]}{\sqrt{\sum_{i=1}^N (y_i^{exp} - \hat{y}^{exp})^2} \sqrt{\sum_{i=1}^N (y_i^{cal} - \hat{y}^{cal})^2}}$$

## III.4. Résultats et discussions

### III.4.1. Architectures des modèles neuronaux obtenus

Les résultats de l'optimisation des configurations des réseaux de neurones artificiels appliquées à chaque segment sont résumés dans les tableaux suivant :

**Tableau 6 : Les résultats de l'optimisation des architectures des RNA pour la viscosité**

	Division	Itération	RN Optimale	MAARD	R	Fonction de Transfert CC	Fonction de Transfert CS
<b><i>AL<sub>2</sub>O<sub>3</sub></i> viscosité</b>	60-20-20	100	4-[20-10]-1	App=1.855	0.958	logsig	Tansig
				Tes= 0.590	0.838		
				Val= 0.162	0.943		
				Glob = 0.841	0.938		
	300	4-[25-10]-1	App=0.117	0.964	tansig	Logsig	
			Tes= 1.774	0.848			
			Val= 0.653	0.970			
			Glob =0.735	0.950			



**Chapitre III Résultat et discussion**

		500	4-[30-20]-1	App= 1.627 Tes= 0.039 Val= 0.957 Glob = 0.886	0.947 0.879 0.960 0.942	tansig	Logsig
	70-15-15	100	4-[20-10]-1	App=1.607 Tes= 1.066 Val= 0.721 Glob=0.925	0.980 0.874 0.944 0.968	tansig	Logsig
		300	4-[25-10]-1	App= 0.610 Tes= 0.884 Val= 1.660 Glob= 0.819	0.988 0.865 0.933 0.972	logsig	Tansig
		500	4-[30-20]-1	App= 0.608 Tes= 0.976 Val= 0.790 Glob= 0.712	0.982 0.904 0.943 0.972	logsig	Tansig
	80-10-10	100	4-[20-10]-1	App= 0.976 Tes= 1.047 Val= 0.484 Glob=0.850	0.979 0.924 0.957 0.959	logsig	Tansig
		300	4-[25-10]-1	App= 1.325 Tes= 0.530 Val= 0.132 Glob=0.931	0.954 0.998 0.981 0.968	logsig	Tansig
		500	4-[30-20]-1	App= 0.275 Tes= 0.884 Val= 1.579 Glob= 0.994	0.993 0.635 0.965 0.784	tansig	Logsig

**Chapitre III Résultat et discussion**

<b>CuO viscosité</b>	60-20-20	100	4-[20-10]-1	App=1.410 Tes= 0.330 Val=1.996 Glob=0.929	1.000 0.937 0.970 0.999	tansig	Logsig
		300	4-[25-10]-1	App=0.312 Tes=0.514 Val=0.664 Glob=0.683	0.998 0.977 0.982 0.997	logsig	Tansig
		500	4-[30-20]-1	App=0.598 Tes=0.725 Val= 1.959 Glob=0.842	1.000 0.946 0.959 0.999	tansig	Logsig
	70-15-15	100	4-[20-10]-1	App=0.945 Tes=0.808 Val=0.858 Glob=0.943	1.000 0.918 0.985 0.999	logsig	Tansig
		300	4-[25-10]-1	App=1.177 Tes= 0.997 Val=0.804 Glob= 0.874	1.000 0.959 0.992 0.999	logsig	Tansig
		500	4-[30-20]-1	App=0.673 Tes= 0.537 Val=1.922 Glob=0.933	1.000 0.949 0.959 0.999	tansig	Logsig
	80-10-10	100	4-[20-10]-1	App=0.076Tes =1.250 Val=0.736 Glob=0.713	1.000 0.997 0.995 1.000	tansig	Logsig

**Chapitre III Résultat et discussion**

		300	4-[25-10]-1	App=0.339 Tes=0.680 Val=0.932 Glob=0.552	1.000 0.996 0.998 1.000	logsig	Tansig
		500	4-[30-20]-1	App=0.503 Tes= 1.354 Val=1.318 Glob=0.933	1.000 0.992 0.984 1.000	logsig	Tansig

**Tableau 7 : Les résultats de l'optimisation des architectures des RNA pour la conductivité**

	Division	Itération	RN Optimale	MAARD	R	Fonction de Transfert CC	Fonction de Transfert CS
<b>Al<sub>2</sub>O<sub>3</sub> conductivité</b>	60-20-20	100	4-[20-10]-1	App= 0.859 Tes= 1.894 Val= 0.621 Glob=0.930	0.979 0.872 0.936 0.952	logsig	Tansig
		300	4-[25-10]-1	App= 0.912 Tes= 0.769 Val= 0.825 Glob= 0.978	0.979 0.924 0.900 0.953	tansig	Logsig
		500	4-[30-20]-1	App= 0.863 Tes= 1.206 Val= 0.730 Glob= 0.838	0.979 0.928 0.938 0.961	tansig	Logsig
	70-15-15	100	4-[20-10]-1	App= 1.072	0.970	logsig	Tansig

**Chapitre III Résultat et discussion**

				Tes= 1.083 Val= 0.795 Glob=0.855	0.834 0.912 0.943			
		300	4-[25-10]-1	App= 0.984 Tes=0.976 Val=0.719 Glob=0.770	0.979 0.916 0.924 0.961	tansig	Logsig	
		500	4-[30-20]-1	App= 0.905 Tes= 0.965 Val= 0.944 Glob=0.905	0.977 0.746 0.914 0.932	logsig	Tansig	
	80-10-10		100	4-[20-10]-1	App= 0.932 Tes= 0.389 Val= 0.475 Glob=0.845	0.977 0.946 0.946 0.971	tansig	logsig
			300	4-[25-10]-1	App= 0.842 Tes= 0.857 Val= 0.647 Glob= 0.987	0.979 0.936 0.947 0.971	logsig	Tansig
			500	4-[30-20]-1	App= 0.806 Tes= 0.463 Val= 0.415 Glob=0.646	0.980 0.931 0.954 0.972	tansig	Logsig
<b>CuO</b> conductivité	60-20-20	100	4-[20-10]-1	App= 0.190 Tes= 1.916 Val= 1.879 Glob=0.945	0.995 0.705 0.738 0.885	tansig	Logsig	
		300	4-[25-10]-1	App= 1.422 Tes= 0.820	0.991 0.642	tansig	logsig	

**Chapitre III Résultat et discussion**

				Val=0.819 Glob=0.823	0.663 0.871		
		500	4-[30-20]-1	App=0.824 Tes= 0.986 Val=0.797 Glob=0.702	0.993 0.724 0.735 0.880	logsig	tansig
	70-15-15	100	4-[20-10]-1	App=0.947 Tes= 0.825 Val= 0.968 Glob= 0.901	0.994 0.627 0.595 0.902	logsig	Tansig
		300	4-[25-10]-1	App=0.511 Tes= 0.501 Val=0.770 Glob=0.678	0.995 0.551 0.523 0.881	logsig	Tansig
		500	4-[30-20]-1	App=0.930 Tes= 0.994 Val=0.968 Glob=0.985	0.992 0.312 0.172 0.794	logsig	Tansig
		100	4-[20-10]-1	App= 0.957 Tes= 1.125 Val= 0.321 Glob== 0.883	0.995 0.866 0.805 0.968	logsig	Tansig
	80-10-10	300	4-[25-10]-1	App= 0.167 Tes= 0.597 Val= 1.605 Glob=0.428	0.996 0.909 0.875 0.978	tansig	Logsig
		500	4-[30-20]-1	App= 0.295 Tes= 1.084 Val= 1.472	0.994 0.934 0.778	logsig	Tansig

### Chapitre III Résultat et discussion

				Glob=0.587	0.972		
--	--	--	--	------------	-------	--	--

D'après le (tableau 7) de viscosité et (tableau 6) de conductivité , les meilleures architectures du RNA et de :

- $\text{CuO} \left\{ \begin{array}{l} 4 - [25 - 10] - 1 \text{ pour la division } 80\% \ 10\% \ 10\% \\ 4 - [25 - 10] - 1 \text{ pour la division } 80\% \ 10\% \ 10\% \end{array} \right\}$
- $\text{Al}_2\text{O}_3 \left\{ \begin{array}{l} 4 - [30 - 20] - 1 \text{ pour la division } 70\% \ 15\% \ 15\% \\ 4 - [30 - 20] - 1 \text{ pour la division } 80\% \ 10\% \ 10\% \end{array} \right\}$

**Tableau 8 : Architecture du meilleur modèle obtenu.**

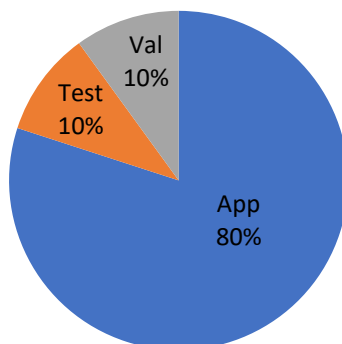
<b>CuO</b>	<b>viscosité</b>		<b>Conductivité</b>	
	<b>Nombre de neurones</b>	<b>Fonctions d'activation</b>	<b>Nombre de neurones</b>	<b>Fonctions d'activation</b>
<b>Couche d'entrée</b>	4	(Aucune)	4	(Aucune)
<b>Couche cachée</b>	25	Logsig	25	Tansig
	10	Tansig	10	Logsig
<b>Couche de sortie</b>	1	Purelin	1	Purelin
<b>Algorithme d'App</b>	Trainlm		Trainlm	
<b>Fonction d'erreur</b>	MSE		MSE	
<b>Valeurs de R et MAARD</b>	MAARD	R	MAARD	R
	App=0.339	1.000	App= 0.167	0.996
	Tes=0.680	0.996	Tes= 0.597	0.909
	Val=0.932	0.998	Val= 1.605	0.875
	Glob=0.552	1.000	Glob=0.428	0.978


<b>AL2O3</b>	<b>viscosité</b>		<b>Conductivité</b>	
	<b>Nombre de neurones</b>	<b>Fonctions d'activation</b>	<b>Nombre de neurones</b>	<b>Fonctions d'activation</b>
<b>Couche d'entrée</b>	4	(Aucune)	4	(Aucune)
<b>Couche cachée</b>	30	Logsig	30	Tansig

### Chapitre III Résultat et discussion

	20	Tansig	20	Logsig
<b>Couche de sortie</b>	1	Purelin	1	Purelin
<b>Algorithme d'App</b>	trainlm		Trainlm	
<b>Fonction d'erreur</b>	MSE		MSE	
<b>Valeurs de R et MAARD</b>	MAARD	R	MAARD	R
	App= 0.608	0.982	App= 0.806	0.980
	Tes= 0.976	0.904	Tes= 0.463	0.931
	Val= 0.790	0.943	Val= 0.415	0.954
	Glob= 0.712	0.972	Glob=0.646	0.972

**Al2O3 pour conductivité**  
**CuO pour viscosité et conductivité**





**Figure 14 : Graphique représentant la meilleure division de la base de données.**

Les résultats obtenus à partir des modèles neuronaux conçus et optimisés sont particulièrement encourageants. Les valeurs de MAARD pour les paramètres de viscosité et de conductivité sont considérées comme relativement acceptables, ce qui indique que ces modèles sont capables de fournir des prédictions précises et cohérentes pour ces deux paramètres. De plus, les coefficients de corrélation R, qui sont proches de l'unité, soulignent la remarquable efficacité de la méthodologie neuronale mise au point. au cours de cette étude. Ces résultats témoignent de la capacité des modèles neuronaux à bien généraliser au-delà de l'ensemble d'apprentissage, car les valeurs MAARD restent acceptables sur les ensembles de test et de validation. Cela renforce la confiance dans la fiabilité de ces modèles pour prédire les valeurs de viscosité et de conductivité,


### **III.4.2. Estimation de la performance du meilleur modèle neuronale**

#### **III.4.2.1. . Comparaison graphique entre les valeurs**

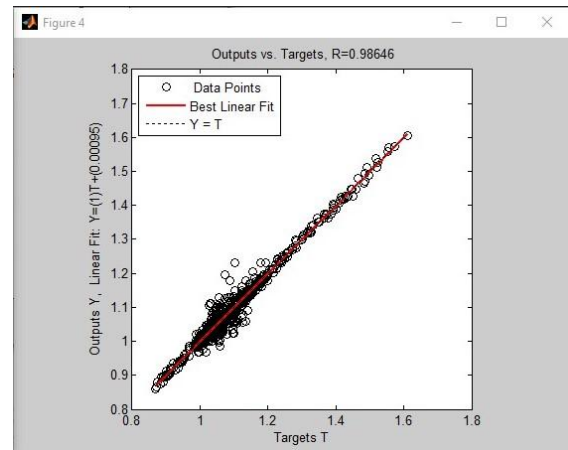
L'analyse comparative entre les valeurs expérimentales de viscosité et de conductivité d'une part, et les valeurs prédites par nos modèles neuronaux optimaux d'autre part, comme illustré dans la (Figure 14), révèle une concordance remarquable entre la théorie et la réalité. Cette concordance est particulièrement manifeste par l'alignement des points de données le long de la bissectrice, indiquant que nos modèles sont capables de reproduire avec précision les comportements complexes de ces paramètres physiques.




### Chapitre III Résultat et discussion




(a)



(b)



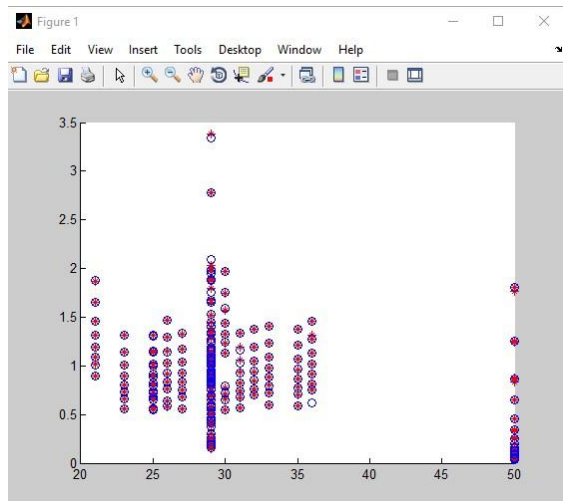
(c)




(d)

**Figure 15 : Comparaison entre les valeurs expérimentales et celle calculées a Base global :  
(a) Al<sub>2</sub>O<sub>3</sub>viscosité , (b) Al<sub>2</sub>O<sub>3</sub> conductivité, (c) CuOviscosité , (d) CuO conductivité**


### III.4.2.2. Comparaison graphique entre les valeurs calculer et les valeurs experimentales de viscosité et de conductivité.



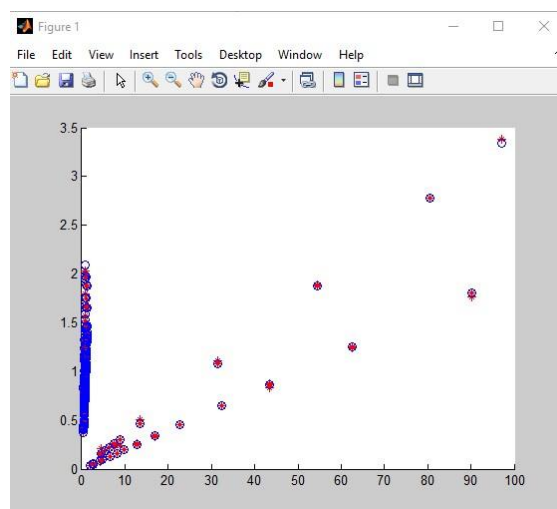
(a)



(b)




(c)

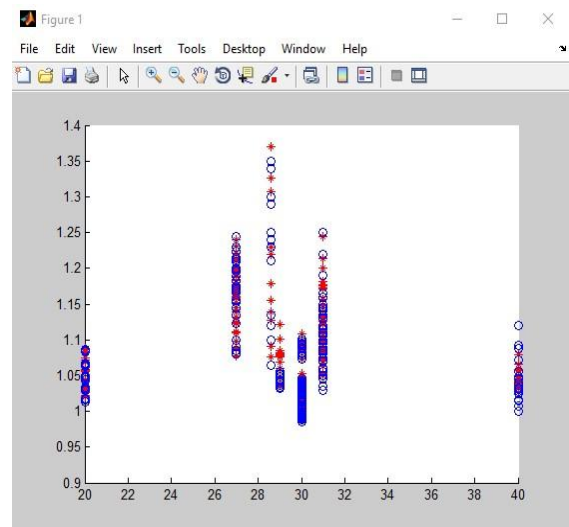


(d)


**Figure 16 : valeurs calculer et les valeurs experimentales de viscosité de CuO on fonction de (a) Taille (b) Fraction volumique (c) Température (d) fluide de base**




(a)



(b)

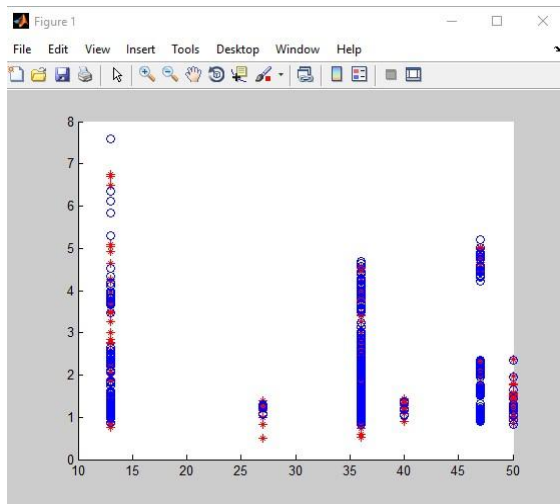


(c)




(d)

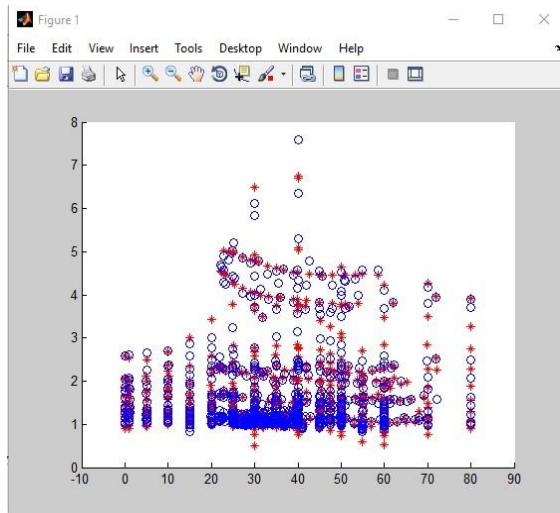
**Figure 17 : valeurs calculer et les valeurs experimentales de conductivité de CuO on fonction de (a) Température (b) Taille (c) Fraction volumique (d) fluide de base**




(a)



(b)




(c)




(d)


**Figure 18 : valeurs calculer et les valeurs experimantales de viscosité de Al<sub>2</sub>O<sub>3</sub> on fonction de (a)Taille (b)Fraction volumique(c)Température(d) fluide de base**




(a)



(b)



(c)



(d)

**Figure 19 : valeurs calculer et les valeurs experimantales de conductivité de Al<sub>2</sub>O<sub>3</sub> on fonction de (a) Taille (b)Température(c) Fraction volumique (d) fluide de base**

Il convient de souligner que toutes les valeurs de viscosité et de conductivité, qu'elles soient expérimentales ou calculées dans le contexte de cette recherche, démontrent une remarquable proximité les unes par rapport aux autres pour un même paramètre. Cette cohérence renforce davantage la confiance en la stabilité et la robustesse de notre modèle neuronal. La faible variabilité entre les données expérimentales et les prévisions du modèle témoigne de la capacité de notre méthodologie à capturer avec précision les propriétés des matériaux étudiés.

Une fois que le modèle neuronal a été développé, il est possible de représenter son équation de la manière suivante.

$$A = \sum_{i=1}^4 f(x_i w_i + b_i)$$

$$B = \sum_{j=1}^{N1} g(x_j w_j + b_j)$$

$$K = \sum_{k=1}^{N2} h(x_k w_k + b_k)$$

$$V = \sum_{v=1}^{N2} h(x_v w_v + b_v)$$

4 est le nombre de neurones dans la couche d'entrée

$N1$  est le nombre de neurones dans la couche cachée 1.

$N2$  est le nombre de neurones dans la couche cachée 2.

$\mathbf{W X b}$  sont les poids et biais de des couches cachée.

$\mathbf{b}_k, \mathbf{b}_v$  sont les poids et biais de la couche de sortie.

$\mathbf{f}$  et  $\mathbf{g}$  sont les fonctions d'activation "tansig" et "logsig" utilisée dans les couches cachée.

$\mathbf{h}$  est la fonction d'activation "purelin" utilisée dans la couche de sortie.

## Conclusion

Nous avons entrepris une démarche visant à élaborer un modèle permettant de représenter de manière précise la conductivité et la viscosité d'un nanofluide composé d' $\text{Al}_2\text{O}_3$  ou  $\text{CuO}$ . Ce processus de modélisation a été divisé en plusieurs phases cruciales, notamment l'apprentissage, le test et la validation.

Dans un premier temps, nous avons alimenté notre réseau de neurones en données pertinentes, permettant ainsi au modèle de s'entraîner et d'apprendre les relations complexes entre les différentes variables du nanofluide. Une fois cette phase d'apprentissage achevée, nous sommes passés à l'étape de test, durant laquelle nous avons évalué la capacité du modèle à généraliser ses prédictions à partir de données non utilisées pendant l'apprentissage.

Cependant, notre démarche ne s'est pas arrêtée là. Nous avons également soumis le modèle à une phase de validation rigoureuse pour garantir sa robustesse et sa fiabilité. Les résultats que nous avons obtenus à cette étape étaient extrêmement encourageants. Le coefficient de détermination, représenté par  $R$ , s'est élevé à des niveaux très élevés, soit pour la conductivité de  $\text{Al}_2\text{O}_3$  et  $\text{CuO}$  respectivement  $\{0,932 ; 0,972\}$   $\{0,794 ; 0,978\}$ , et de la viscosité  $\{0,784 ; 0,972\}$   $\{0,997 ; 1,000\}$  pour chacune des deux sorties que nous étudions. Cela signifie que notre modèle a réussi à expliquer la variation de la conductivité et la viscosité du nanofluide avec une précision exceptionnelle.

De plus, nous avons calculé Mean Absolute Absolute Relative Difference MAARD, qui s'est révélée être  $\{0,646 ; 0,987\}$   $\{0,428 ; 0,985\}$  pour la conductivité de  $\text{Al}_2\text{O}_3$  et  $\text{CuO}$  respectivement et de viscosité  $\{0,712 ; 0,994\}$   $\{0,552 ; 0,943\}$ . Ces valeurs indiquent que notre modèle présente une performance remarquable en minimisant les erreurs entre ses prédictions et les données réelles. Cette faible erreur confirme la fiabilité et la robustesse de notre modèle de réseau de neurones dans la modélisation de la conductivité et la viscosité du nanofluide  $\text{Al}_2\text{O}_3$  et  $\text{CuO}$ .

## **Conclusion générale :**

Dans cette étude, nous avons exploré la modélisation des propriétés thermophysiques des nanofluides, en mettant particulièrement l'accent sur la viscosité et la conductivité thermique. Les nanofluides, qui sont des suspensions de nanoparticules dans un liquide de base, présentent un grand potentiel dans le but d'optimiser le transfert de chaleur et la dissipation thermique dans diverses applications. Cependant, la prédiction précise de leurs propriétés thermophysiques est un défi en raison de la complexité des éléments qui ont un impact sur ces propriétés.

Nous avons utilisé une méthode qui se fonde sur les Réseaux Neuronaux Artificiels (RNA) pour modéliser la conductivité thermique et la viscosité des nanofluides composés de nanoparticules d' $\text{Al}_2\text{O}_3$  et de  $\text{CuO}$  dispersées dans différents fluides de base. Cette approche nous a permis de capturer les relations complexes entre les paramètres clés tels que la concentration en nanoparticules, la température, la taille des particules et les propriétés thermophysiques des nanofluides.

Les résultats de cette modélisation ont démontré que les modèles basés sur des réseaux de neurones optimisés étaient capables de prédire avec précision la viscosité et la conductivité thermique des nanofluides pour différentes conditions expérimentales. Les valeurs de MAARD et de coefficient de corrélation  $R$  obtenues étaient très proches de l'unité, ce qui indique une performance élevée de nos modèles.

De plus, nous avons comparé les valeurs prédites par nos modèles aux données expérimentales, et nous avons constaté une excellente concordance entre les deux ensembles de données, ce qui confirme la fiabilité de nos modèles.

En conclusion, cette étude a démontré l'efficacité des Réseaux Neuronaux Artificiels dans la modélisation des propriétés thermophysiques des nanofluides. Ces modèles pourraient être utilisés pour prédire ces propriétés pour différentes combinaisons de paramètres, ce qui pourrait être utile pour l'optimisation de l'utilisation des nanofluides dans des applications liées au transfert de chaleur et à la dissipation thermique. De plus, cette approche pourrait réduire la nécessité de coûteuses expériences pour déterminer ces propriétés, ce qui pourrait représenter un gain de temps et de ressources significatif pour les chercheurs et les ingénieurs travaillant dans ce domaine.



## Références

- [1] H. Chiam, W. Azmi, N. Usri, R. Mamat, N. Adam, Thermal conductivity and viscosity of Al<sub>2</sub>O<sub>3</sub> nanofluids for different based ratio of water and ethylene glycol mixture, *Exp. Thermal Fluid Sci.* 81 (2017) 420–429.
- [2] H.E. Patel, T. Sundararajan, S.K. Das, An experimental investigation into the thermal conductivity enhancement in oxide and metallic nanofluids, *J. Nanopart. Res.* 12 (3) (2010) 1015–1031.
- [3] J.R. Satti, D.K. Das, D. Ray, Investigation of the thermal conductivity of propylene glycol nanofluids and comparison with correlations, *Int. J. Heat Mass Transf.* 107(2017) 871–881.
- [4] M. Sharif, W. Azmi, A. Redhwan, R. Mamat, Investigation of thermal conductivity and viscosity of Al<sub>2</sub>O<sub>3</sub>/PAG nanolubricant for application in automotive air conditioning system, *Int. J. Refrig.* 70 (2016) 93–102.
- [5] L.S. Sundar, M.H. Farooky, S.N. Sarada, M. Singh, Experimental thermal conductivity of ethylene glycol and water mixture based low volume concentration of Al<sub>2</sub>O<sub>3</sub> and CuO nanofluids, *Int. Commun. Heat Mass Transf.* 41(2013) 41–46.
- [6] L.S. Sundar, E.V. Ramana, M.K. Singh, A.C. Sousa, Thermal conductivity and viscosity of stabilized ethylene glycol and water mixture Al<sub>2</sub>O<sub>3</sub> nanofluids for heat transfer applications: an experimental study, *Int. Commun. Heat Mass Transf.* 56 (2014) 86–95.
- [7] R. S. Vajjha and D. K. Das, “Experimental determination of thermal conductivity of three nanofluids and development of new correlations,” *International Journal of Heat and Mass Transfer*, vol. 52, no. 21–22, pp. 4675–4682, Oct. 2009.
- [8] A. M. Hussein, R. A. Bakar, K. Kadirgama, and K. v. Sharma, “Experimental measurement of nanofluids thermal properties,” *International Journal of Automotive and Mechanical Engineering*, vol. 7, no. 1, pp. 850–863, 2013.
- [9] S. Lee, S. Choi, S. Li, and J. A. Eastman, “Measuring Thermal Conductivity of Fluids Containing Oxide Nanoparticles,” 1999. [Online]. Available: [http://asmedigitalcollection.asme.org/heattransfer/article-pdf/121/2/280/5757557/280\\_1.pdf](http://asmedigitalcollection.asme.org/heattransfer/article-pdf/121/2/280/5757557/280_1.pdf)
- [10] X. Wang, X. Xu, and S. U. S. Choi, “Thermal conductivity of nanoparticle-fluid mixture,” *Journal of thermophysics and heat transfer*, vol. 13, no. 4, pp. 474–480, 1999.
- [11] C. H. Li and G. P. Peterson, “Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids),” *Journal of Applied Physics*, vol. 99, no. 8, 2006.
- [12] H. A. Mintsas, G. Roy, C. T. Nguyen, and D. Doucet, “New temperature dependent thermal conductivity data for water-based nanofluids,” *International Journal of Thermal Sciences*, vol. 48, no. 2, pp. 363–371, Feb. 2009.
- [13] M. Hemmat Esfe, A. Karimipour, W. M. Yan, M. Akbari, M. R. Safaei, and M. Dahari, “Experimental study on thermal conductivity of ethylene glycol based nanofluids containing Al<sub>2</sub>O<sub>3</sub> nanoparticles,” *International Journal of Heat and Mass Transfer*, vol. 88, pp. 728–734, Sep. 2015.
- [14] B. Barbés et al., “Thermal conductivity and specific heat capacity measurements of Al<sub>2</sub>O<sub>3</sub> nanofluids,” *Journal of Thermal Analysis and Calorimetry*, vol. 111, no. 2, pp. 1615–1625, Feb. 2013.
- [15] M. P. Beck et al. “The effect of particle size on the thermal conductivity of alumina nanofluids”. In: *Journal of Nanoparticle Research* 11.5 (2009), pp. 1129–1136.

- [16] N. Bouguerra, S. Poncet, and S. Elkoun. “Dispersion regimes in alumina/water-based nanofluids: Simultaneous measurements of thermal conductivity and dynamic viscosity”. In: *International Communications in Heat and Mass Transfer* 92 (2018), pp. 51–55.
- [17] J. Bowers et al. “Flow and heat transfer behaviour of nanofluids in microchannels”. In: *Progress in Natural Science: Materials International* 28.2 (2018), pp. 225–234.
- [18] M. Chandrasekar and S. Suresh. “Experiments To Explore The Mechanisms Of Heat Transfer In Nanocrystalline Alumina/Water Nanofluid Under Laminar And Turbulent Flow Conditions”. In: *Experimental Heat Transfer* 24.3 (2011), pp. 234–256.
- [19] C. H. Chon et al. “Empirical correlation finding the role of temperature and particle size for nanofluid (Al<sub>2</sub>O<sub>3</sub>) thermal conductivity enhancement”. In: *Applied Physics Letters* 87.15 (2005), p. 153107.
- [20] P. K. Das et al. “Stability and thermophysical measurements of TiO<sub>2</sub> (anatase) nanofluids with different surfactants”. In: *Journal of Molecular Liquids* 254 (2018), pp. 98–107.
- [21] T. A. El-Brolossy and O. Saber. “Non-intrusive method for thermal properties measurement of nanofluids”. In: *Experimental Thermal And Fluid Science* 44 (2013), pp. 498–503.
- [22] M. Hemmat Esfe et al. “Thermal conductivity of Al<sub>2</sub>O<sub>3</sub>/water nanofluids”. In: *Journal of Thermal Analysis and Calorimetry* 117.2 (2014), pp. 675–681.
- [23] R. Gangadevi, B. K. Vinayagam, and S. Senthilraja. “Effects of sonication time and temperature on thermal conductivity of CuO/water and Al<sub>2</sub>O<sub>3</sub>/water nanofluids with and without surfactant”. In: *Materials Today: Proceedings* 5.2, Part 3 (2018), pp. 9004–9011.
- [24] A. Gavili and T. Isfahani. “Experimental investigation of transient heat transfer coefficient in natural convection with Al<sub>2</sub>O<sub>3</sub>-nanofluids”. In: *Heat and Mass Transfer* (2019).
- [25] R. Gowda et al. “Effects of Particle Surface Charge, Species, Concentration, and Dispersion Method on the Thermal Conductivity of Nanofluids”. In: *Advances In Mechanical Engineering* (2010).
- [26] M. M. Heyhat et al. “Experimental investigation of turbulent flow and convective heat transfer characteristics of alumina water nanofluids in fully developed flow regime”. In: *International Communications in Heat And Mass Transfer* 39.8 (2012), pp. 1272–1278.
- [27] C. J. Ho and Y. J. Lin. “Turbulent forced convection effectiveness of alumina-water nanofluid in a circular tube with elevated inlet fluid temperatures: An experimental study”. In: *International Communications In Heat And Mass Transfer* 57 (2014), pp. 247–253.
- [28] J. Hong and D. Kim. “Effects of aggregation on the thermal conductivity of alumina/water nanofluids”. In: *Thermochimica Acta* 542.SI (2012), pp. 28–32.
- [29] F. Iacobazzi et al. “An explanation of the Al<sub>2</sub>O<sub>3</sub> nanofluid thermal conductivity based on the phonon theory of liquid”. In: *Energy* 116.1 (2016), pp. 786–794.
- [30] M. H. Kayhani et al. “Experimental analysis of turbulent convective heat transfer and pressure drop of Al<sub>2</sub>O<sub>3</sub>/water nanofluid in horizontal tube”. In: *Micro & Nano Letters* 7.3 (2012), pp. 223–227.
- [31] S. Kim et al. “Experimental investigation of dispersion characteristics and thermal conductivity of various surfactants on carbon based nanomaterial”. In: *International Communications in Heat and Mass Transfer* 91 (2018), pp. 95–102.
- [32] N. Kumar, S. S. Sonawane, and S. H. Sonawane. “Experimental study of thermal conductivity, heat transfer and friction factor of Al<sub>2</sub>O<sub>3</sub> based nanofluid”. In: *International Communications in Heat and Mass Transfer* 90 (2018), pp. 1–10.
- [33] X. F. Li et al. “Thermal conductivity enhancement dependent pH and chemical surfactant for Cu-H<sub>2</sub>O nanofluids”. In: *Thermochimica Acta* 469.1 (2008), pp. 98–103.
- [34] V. Mikkola et al. “Influence of particle properties on convective heat transfer of nanofluids”. In: *International Journal of Thermal Sciences* 124 (2018), pp. 187–195.

- [35] M. Modi, P. Kangude, and A. Srivastava. “Performance evaluation of alumina nanofluids and nanoparticles deposited surface on nucleate pool boiling phenomena”. In: *International Journal of Heat and Mass Transfer* 146 (2020), p. 118833.
- [36] S. M. S. Murshed, K. C. Leong, and C. Yang. “Investigations of thermal conductivity and viscosity of nanofluids”. In: *International Journal of Thermal Sciences* 47.5 (2008), pp. 560–568.
- [37] V. Nair, A. D. Parekh, and P. R. Tailor. “Water-based Al<sub>2</sub>O<sub>3</sub>, CuO and TiO<sub>2</sub> nanofluids as secondary fluids for refrigeration systems: a thermal conductivity study”. In: *Journal of the Brazilian Society of Mechanical Sciences and Engineering* 40.5 (2018), p. 262.
- [38] D.-W. Oh et al. “Thermal conductivity measurement and sedimentation detection of aluminum oxide nanofluids by using the 3! method”. In: *International Journal of Heat and Fluid Flow* 29.5 (2008), pp. 1456–1461.
- [39] H. E. Patel, T. Sundararajan, and S. K. Das. “An experimental investigation into the thermal conductivity enhancement in oxide and metallic nanofluids”. In: *Journal of Nanoparticle Research* 12.3 (2010), pp. 1015–1031.
- [40] B. Ruan and A. M. Jacobi. “Investigation on Intertube Falling-Film Heat Transfer and Mode Transitions of Aqueous-Alumina Nanofluids”. In: *Journal Of Heat Transfer-Transactions of the ASME* 133.5 (2011).
- [41] V. Y. Rudyak, A. V. Minakov, and S. L. Krasnolutski. “Physics and mechanics of heat exchange processes in nanofluid flows”. In: *Physical Mesomechanics* 19.3 (2016), pp. 298–306.
- [42] Z. Said et al. “Rheological behaviour and the hysteresis phenomenon of Al<sub>2</sub>O<sub>3</sub> nanofluids”. In: *Material Research Innovations* 18.S6 (2014), pp. 47–50.
- [43] T.-P. Teng et al. “The effect of alumina/water nanofluid particle size on thermal conductivity”. In: *Applied Thermal Engineering* 30.14 (2010), pp. 2213–2218.
- [44] A. Topuz et al. “Experimental investigation of optimum thermal performance and pressure drop of water-based Al<sub>2</sub>O<sub>3</sub>, TiO<sub>2</sub> and ZnO nanofluids flowing inside a circular microchannel”. In: *Journal of Thermal Analysis and Calorimetry* 131.3 (2018), pp. 2843–2863.
- [45] A. Vakilinejad et al. “Experimental and theoretical investigation of thermal conductivity of some water-based nanofluids”. In: *Chemical Engineering Communications* 205.5 (2018), pp. 610–623.
- [46] D. Zhu et al. “Dispersion behavior and thermal conductivity characteristics of Al<sub>2</sub>O<sub>3</sub>–H<sub>2</sub>O nanofluids”. In: *Current Applied Physics* 9.1 (2009), pp. 131–139.
- [47] G. Singh Sokhal, D. Gangacharyulu, and V. K. Bulasara. “Influence of copper oxide nanoparticles on the thermophysical properties and performance of flat tube of vehicle cooling system”. In: *Vacuum* 157 (2018), pp. 268–276.
- [48] Lotfizadeh Dehkordi, B., Kazi, S. N., & Hamdi, M. (2013). *Viscosity of ethylene glycol+ water based Al<sub>2</sub>O<sub>3</sub> nanofluids with addition of SDBS dispersant*. *Processing and Properties of Advanced Ceramics and Composites V: Ceramic Transactions*, 240, 211-218.
- [49] Prasher, R., Song, D., Wang, J., & Phelan, P. (2006). *Measurements of nanofluid viscosity and its implications for thermal applications*. *Applied physics letters*, 89(13), 133108.
- [50] Masuda, H., Ebata, A., & Teramae, K. (1993). *Alteration of thermal conductivity and viscosity of liquid by dispersing ultra-fine particles. Dispersion of Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> and TiO<sub>2</sub> ultra-fine particles*.
- [51] Sekhar, Y. R., & Sharma, K. V. (2015). *Study of viscosity and specific heat capacity characteristics of water-based Al<sub>2</sub>O<sub>3</sub> nanofluids at low particle concentrations*. *Journal of experimental Nanoscience*, 10(2), 86-102.
- [52] C. Nguyen, F. Desgranges, G. Roy, N. Galanis, T. Mare, S. Boucher, H. Anguemintsa, *Temperature and particle-size dependent viscosity data for water-based nanofluids – hysteresis phenomenon*, *Int. J. Heat Fluid Flow* 28(6) (2007) 1492–1506.
- [53] M. Kole, T.K. Dey, *Viscosity of alumina nanoparticles dispersed in car engine coolant*, *Exp. Therm. Fluid Sci.* 34 (6) (2010) 677–683.

- [54] Namburu, P. K., Kulkarni, D. P., Misra, D., & Das, D. K. (2007). *Viscosity of copper oxide nanoparticles dispersed in ethylene glycol and water mixture*. *Experimental Thermal and Fluid Science*, 32(2), 397-402.
- [55] M.J. Pastoriza-Gallego, C. Casanova, J.L. Legido, M.M. Piñeiro, *CuO in water nanofluid: influence of particle size and polydispersity on volumetric behaviour and viscosity*, *Fluid Phase Equilib.* 300 (1–2) (2011) 188–196.
- [56] M.T. Naik, G.R. Janardhana, K.V.K. Reddy, B.S. Reddy, *Experimental investigation into rheological property of copper oxide nanoparticles suspended in propylene glycol- water based fluids*, *ARPJ. Eng. Appl. Sci.* 5(6) (2010) 29–34.
- [57]. Schenker B. et Agarwal M. (1998). "Predictive control of a bench-scale chemical reactor based on neural-network models." *Control Systems Technology, IEEE Transactions on* 6(3): 388-400.
- [58] Hamadache, M., Benkortbi, O., Hanini, S., Amrane, A., Khaouane, L., & Moussa, C. S. (2016a). A quantitative structure activity relationship for acute oral toxicity of pesticides on rats: validation, domain of application and prediction. *Journal of hazardous materials*, 303, 28-40