



**Faculté des Sciences et des Sciences Appliquées
Département de Génie Mécanique**

PROJET DE FIN D'ETUDE

Présenté pour l'obtention du Diplôme de Master
Spécialité : Génie mécanique
Option : Énergétique

THEME

**Modélisation prédictive des propriétés thermophysiques des
nanaofluides par méthode d'intelligence artificiel**

Par :

AKKOUCHE Mounia

Soutenu le 29/06/2025 devant le jury composé

Dr.MAHFOUD Brahim

Université de Bouira

Président

Dr.MOUSSAOUI Mouhamed

Université de Bouira

Promoteur

Dr.BENSALEM Chafik

Université de Bouira

Examineur



نموذج التصريح الشرفي الخاص بالالتزام بقواعد النزاهة العلمية لإنجاز بحث.

انا الممضي اسفله،

السيد(ة)..... علوش حنية..... الصفة: طالب، اسكاذ، باحث..... لمجال.....
الحامل(ة) لبطاقة التعريف الوطنية:..... 114569006..... والصادرة بتاريخ..... 14/05/2019
المسجل(ة) بكلية / معهد..... علم و تكنولوجيا..... قسم..... هندسة ميكانيكية.....
والمكلف(ة) بإنجاز اعمال بحث(مذكرة، التخرج، مذكرة ماستر، مذكرة ماجستير، اطروحة دكتوراه).
عنوانها:..... Modelisation prédictive des propriétés thermophysiques
des nanofluides Avec méthodes d'intelligence Artificielle.....
تحت إشراف الأستاذ(ة):..... جميع مساري.....
أصرح بشرفي اني ألتزم بمراعاة المعايير العلمية والمنهجية الاخلاقيات المهنية والنزاهة الاكاديمية المطل
في انجاز البحث المذكور أعلاه.

التاريخ:..... 2019/06/19

توقيع المعني(ة)

رأي هيئة مراقبة السرقة العلمية:

النسبة: % 24

الامضاء:



Faculté des Sciences Appliquées
Département de Génie Mécanique

**Autorisation de déposer un mémoire de Master
pour soutenance**

Je soussigné, l'enseignant (e) :

..... *MOUSSAOUI Mohammed*

L'encadrant du mémoire de fin d'études des étudiants :

1- *AKKACHE MOUNIA*

2-

Ayant le mémoire de fin d'études de Master intitulé :

..... *Modélisation Prédictive des propriétés thermophysiques
des nanofluides par méthode d'intelligence artificielle*

Promotion : 2024/ 2025

Et après avoir consulté le mémoire dans sa forme finale j'autorise les étudiants à
déposer pour la soutenance.

Signature du L'encadrant

Bouira le : *19/06/2025*

Chef de département

Bouira le : *19/06/2025*



Remerciement

Nous tenons à remercier notre Dieu, le tout puissant, de nous avoir donné la santé et la volonté pour compléter ce modeste travail.

Nos remerciements les plus chaleureux vont à nos **chers parents, mes sœurs, mes frères et mes amis** pour leurs encouragements, leur patience, et leur grand soutien durant toutes ces années d'études.

Nos remerciements s'adressent également au docteur **MOUSSAOUI Mouhamed** pour son encadrement, sa motivation professionnelle, son orientation afin de donner notre mieux.

Nos profondes gratitudes aux membres du jury qui ont l'honneur d'évaluer ce travail de fin d'études.

Tous nos vifs remerciements vont à tous les enseignants qui ont contribué à notre Formation durant notre cursus universitaire.

Enfin, nous tenons à remercier également tous ceux qui nous ont aidé de près ou de loin pour l'élaboration de ce mémoire.

A tous ceux dont le soutien nous a été utile et nécessaire

Dédicace

Ce mémoire représente bien plus que de simples travaux. Ce mémoire est la finalité de cinq longues années d'études. C'est pourquoi je tiens à exprimer ma reconnaissance et ma sympathie bien que je dédie ce travail :

A mes chers parents, mes piliers, que dieu me les gardes

Que ce mémoire soit le meilleur cadeau que je puisse vous offrir

A mes frères et mes sœurs que j'adore

KHALED, OUAZNA, SILIA, Fani, LINA, RAYAN

A celles que je considère comme des sœurs

Celina , Samah, Dihia ,Lilich, Amina, Katia

Qui m'avais toujours soutenu

Et encouragé durant ces années d'études

A tous ceux que j'aime et ceux qui m'aiment

...

Mounia

Résumé :

Cette étude présente la mise en œuvre d'un perceptron multicouche dans l'environnement MATLAB, utilisant l'algorithme de rétropropagation de Levenberg–Marquardt, afin de modéliser le comportement thermophysiques de nanofluides, car grâce à leur conductivité thermique améliorée, trouvent des applications dans de nombreux domaines technologiques et industriels. Le réseau de neurones artificiels développé permet de prédire avec une grande précision les variations de conductivité thermique et de viscosité de l'oxyde d'aluminium (Al_2O_3), l'oxyde de silicium (SiO_2) 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. L'architecture retenue comprend deux couches cachées et un nombre de neurones variant entre 1 et 60, assurant ainsi un équilibre optimal entre précision et simplicité. L'excellent valeur de MAARD qui égale à zéro obtenu illustre la remarquable capacité prédictive du modèle, attestant de sa justesse malgré une structure relativement modeste.

Abstract :

This study shows how to use a multilayer perceptron in MATLAB with the Levenberg–Marquardt backpropagation algorithm to model how nanofluids behave thermally. Thanks to their enhanced thermal conductivity, nanofluids find applications in various technological and industrial fields. The developed artificial neural network enables highly accurate prediction of variations in thermal conductivity and viscosity of aluminum oxide (Al_2O_3), silicon dioxide (SiO_2), and copper oxide (CuO), based on parameters such as temperature, volume fraction, base fluid conductivity, and nanoparticle size. The chosen architecture consists of two hidden layers with a number of neurons varying between 1 and 60, thus ensuring an optimal balance between accuracy and simplicity. The excellent MAARD value of zero obtained illustrates the remarkable predictive capability of the model, demonstrating its accuracy despite a relatively modest structure.

ملخص

تُظهر هذه الدراسة كيفية استخدام مُخسب متعدد الطبقات في مع خوارزمية الانتشار الخلفي ليفينبرغ-ماركوارت لنمذجة سلوك الموائع النانوية حراريًا. بفضل موصليتها الحرارية المُحسَّنة، تُستخدم الموائع النانوية في مختلف المجالات التكنولوجية والصناعية. تُمكن الشبكة العصبية الاصطناعية المُطوَّرة من تنبؤ دقيق للغاية بتغيرات الموصلية الحرارية، ولزوجة أكسيد الألومنيوم وأكسيد النحاس وأكسيد السيليكون بناءً على معايير مثل درجة الحرارة، والنسبة الحجمية

وموصلية السائل القاعدي، وحجم الجسيمات النانوية. يتكون الهيكل المُختار من طبقتين مخفيتين مع عدد من الخلايا العصبية يتراوح بين 1 و60، مما يضمن توازنًا مثاليًا بين الدقة والبساطة. تُوضّح قيمة ماارد الممتازة "الصفّر" التي تم الحصول عليها، القدرة التنبؤية المتميزة للنموذج، مما يُظهر دقته على الرغم من بنيته المتواضعة نسبيًا.

Table des matières :

Introduction générale :	1
<i>CHAPITRE I : Généralités sur les Nanofluides :</i>	
I.1. Introduction :	4
I.2. Historique :	4
I.3. Définition de Nanofluide :	7
I.4. Fabrication des nanofluides :	8
I.4.1. La méthode en deux étapes :	9
I.4.2. La méthode en une étape :	10
I.5. Application des nanofluides :	11
I.5.1. Applications du transfert de chaleur :	11
I.5.2. Applications automobiles :	11
I.5.3. Applications électroniques :	11
I.5.4. Applications biomédicales :	12
I.5.5. Défense :	12
I.6. Les nanoparticules et les fluides porteurs :	13
I.6.1. Les nanoparticules :	13
1. Les nanoparticules d'oxydes métalliques :	13
2. Les nanoparticules métalliques :	16
3. Les nanoparticules non métalliques :	16
I.6.2. Les fluides porteurs (fluide de base) :	16
I.7. Les propriétés thermophysiques :	17
I.7.1. La conductivité thermique :	17
1.7.1.1. Modèles de conductivité thermique :	17
I.7.2. Chaleur spécifique (C_p) :	20

I.7.3. Masse volumique (ρ) :	20
I.7.4. Fraction volumique (ϕ) :	21
I.7.5. Viscosité dynamique :	21
I.8. Types des nanofluides :	24
I.8.1. Les nanoparticules sphériques :	24
I.8.2. Les nanotubes :	25
I.9. Les Avantages des nanofluides :	25
I.10. Les Inconvénients des nanofluides :	26
I.11. Revue bibliographie :	26
I.12. Conclusion :	28
II.1. Introduction :	31
II.2. La définition de réseau de neurone (RN) :	31
1. Définition :	31
2. Historique :	32
II.3. Réseaux neuronaux biologiques (Soma) :	34
II.4. Le réseau de neurone artificiel :	36
1) Définition :	36
2) La comparaison entre RNA et RNB :	37
• Machines Learning (ML) :	39
• Deep Learning :	39
II.5. Fonction d'activation de RNA :	39
II.6. Architecture de neurone artificiel :	45
1) Réseau de neurone non bouclée (feed forward) :	45
B. Les réseaux neurones multicouches :	46
2) Réseaux neurone bouclé (feed back) :	47
II.7. L'apprentissage dans les réseaux de neurones :	48
II.8. Référence bibliographique :	49

II.9. Conclusion :	50
III.1. Introduction :	53
III.2. Modélisation prédictive :	53
III.3. Matériel et méthodes :	54
A. Matériels :	54
B. Méthodologie de calcul :	54
1) Collecte de base de données :	55
2) Référence d'extraction des données :	56
3) Description détaillée des données de collecté :	58
4) Division de la base de données :	58
5) Optimisation des architectures des RNA :	60
6) Analyse des erreurs :	62
III.4. Résultats et discussions :	62
1. Résultats des architectures des modèles neuronaux obtenus :	62
2. Les architecture les plus performantes :	67
3. La comparaison graphique des résultats obtenue :	68
III.5. Conclusion :	72
Conclusion générale :	74
Bibliographie :	75

Liste des figures :

Figure I. 1 : schéma sur la procédure de la préparation de nanofluides.	9
Figure I. 2 : UP400St Homogénéisateur Ultrasonique pour la Production de Nanofluides.	10
Figure I. 3: digramme montre les résultats de chaque recherche donnant les valeurs maximales des conductivités thermiques obtenues par le nanofluide Al ₂ O ₃ /eau.	13
Figure I. 4 : comparaison de la conductivité thermique entre les liquides, solides et polymères	16
Figure I. 5 : l'effet de la fraction volumique pour le nanofluide Al ₂ O ₃ /eau pour (150nm)	21
Figure I. 6 : La variation de la viscosité en fonction de champ magnétique et la fraction volumique à 30C°.....	22
Figure I. 7 : La variation de la viscosité en fonction de champ magnétique et la fraction volumique à 40C°.....	22
Figure I. 8 : Image à 3D d'une nanoparticule sphérique	24
Figure I. 9 : nanotube de CARBONE.....	25
Figure II. 1: Images de W. MCCulloch et W. Pitts.....	32
Figure II. 2: le neurone biologique.....	34
Figure II. 3:Fonctionnement au niveau synaptique	35
Figure II. 4 : Principe de fonctionnement d'un neurone artificiel	37
Figure II. 5: Exemple d'un code Matlab pour la sigmoïde pour la visualiser :	43
Figure II. 6: graphe de la fonction ReLU :	44
Figure II. 7: Un simple code pour le ReLU.....	44
Figure II. 8: Le graphe de la fonction softmax.....	45
Figure II. 9: Schéma de réseau neurone monocouche (perceptron) :	46
Figure II. 10: schéma de réseau neurone multicouches :.....	47
Figure II. 11:Schéma de neurone bouclé.....	48
Figure III. 1: schéma de méthodologie de la modélisation neuronale :	55
Figure III. 2: viscosity de l'eau en fonction de température :.....	57
Figure III. 3: conductivité thermique de l'eau en fonction de température :	58
Figure III. 4: Graphique représente les divisions des bases de données :	59
Figure III. 5: Schéma des étapes de l'algorithme de Levenberg Marquardt :	60
Figure III. 6: L'une des architectures de réseau neurone utiliser :.....	61
Figure III. 7: Apprentissage de RNA pour la meilleure architecture de la conductivité de :a)AL ₂ O ₃ ; b)CuO ; c)SiO ₂ :.....	65
Figure III. 8: Apprentissage de RNA pour la meilleure architecture pour la viscosité de AL ₂ O ₃ , CuO et SiO ₂ :.....	67
Figure III. 9: Comparaison graphique entre les valeurs expérimentales et calculer :.....	69

Figure III. 10: Graphe de conductivity calculer et expérimentale en fonction de fraction pour AL ₂ O ₃ et CuO :	70
Figure III. 11: Graphe de conductivity calculer et expérimentale en fonction de température pour AL ₂ O ₃ et SiO ₂ :.....	70
Figure III. 12: Graphe de viscosité calculer et expérimentale pour AL ₂ O ₃ en fonction de :.....	71
Figure III. 13: Graphe de viscosité calculer et expérimentale pour CuO en fonction de température : 71	
Figure III. 14: Graphe de viscosité calculer et expérimentale pour SiO ₂ en fonction de température : 71	

Liste des tableaux :

Tableau I. 1 : : Les résultats obtenues par chaque chercheur depuis 1999 jusqu'à 2008	5
Tableau I. 2: Conductivité thermique de divers fluides de base et martiaux à 20°	17
Tableau II. 1:la comparaison entre les RNB et les RNA :	38
Tableau II. 2: Les fonctions d'activation de la neutral network toolbox de Matlab :	40
Tableau II. 3:La différence entre les réseaux neurones monocouche et multicouches :	47
Tableau III 1:logiciels utilisés :	54
Tableau III 2: Les données des entrées et les sorties :.....	56
Tableau III 3: Référents des données expérimentales :	56
Tableau III 4:Gammes de données expérimentales :.....	58
Tableau III 5: Résultats des architectures des modèles neuronaux obtenus pour la conductivité thermique :.....	62
Tableau III 6: Résultats des architectures des modèles neuronaux obtenus pour la viscosité : 65	
Tableau III 7: les architecture les plus performantes :	67

Introduction générale :

L'intelligence artificielle (IA), en particulier les techniques d'apprentissage automatique (Machine Learning), offre une approche alternative et puissante pour la modélisation des propriétés thermiques des nanofluides. Ces derniers trouvent des applications dans divers domaines, notamment le transfert de chaleur, l'électronique, et les systèmes de refroidissement. En exploitant des bases de données expérimentales, ces techniques permettent de développer des modèles prédictifs capables d'identifier les relations complexes entre les nombreux paramètres influents, tels que la nature des nanoparticules, leur concentration, leur diamètre, ou encore la température.

Dans ce mémoire, l'objectif est de comprendre et d'optimiser ces matériaux innovants à travers une approche basée sur les réseaux de neurones artificiels. Pour atteindre cet objectif, le mémoire est structuré en trois chapitres principaux :

- **Le premier chapitre** est dédié à l'étude des nanofluides. Il présente leur historique, leurs méthodes de fabrication et de préparation, ainsi que les différents types de composants utilisés. Les propriétés thermophysiques des nanofluides y sont détaillées, tout comme leurs nombreuses applications industrielles. Enfin, leurs avantages et leurs inconvénients sont également discutés.
- **Le deuxième chapitre** introduit les réseaux de neurones artificiels. Il commence par une présentation générale et une rétrospective historique de leur évolution, depuis leur conception inspirée du fonctionnement du cerveau humain jusqu'à leur rôle actuel en tant qu'outils essentiels du Machine Learning. Le chapitre aborde ensuite la modélisation du neurone biologique, puis du neurone artificiel, avec ses fonctions d'activation et ses mécanismes d'apprentissage. La structure des réseaux (perceptrons, réseaux multicouches) et les différentes méthodes d'apprentissage (supervisé et non supervisé) sont également explorées.
- **Le troisième chapitre** décrit la méthodologie adoptée pour la mise en œuvre du modèle. Il détaille les outils utilisés, les étapes de la conception du réseau de neurones, de la collecte et la préparation des données jusqu'à la sélection des paramètres optimaux pour obtenir des prédictions précises. Les résultats issus des simulations sont ensuite analysés afin de valider le modèle et d'orienter le choix des nanofluides les plus performants.

Ce mémoire se termine par une conclusion générale qui résume les apports du travail réalisé et propose des perspectives pour de futurs travaux.

Chapitre I :

Généralités sur les Nanofluides

I.1. Introduction :

Au cours des dernières décennies, les besoins en systèmes de transfert de chaleur plus efficaces n'ont cessé d'augmenter, notamment dans des secteurs tels que l'énergie, l'électronique, l'aéronautique ou encore le génie biomédical. Face aux limites des fluides caloporteurs traditionnels, les nanofluides sont apparus comme une solution prometteuse. Il s'agit de suspensions colloïdales composées de nanoparticules métalliques ou non métalliques dispersées dans un fluide de base (eau, huile, éthylène glycol, etc.), offrant des propriétés thermiques supérieures à celles des fluides conventionnels.

Ce chapitre a pour objectif de présenter les fondements essentiels liés aux nanofluides. Il débute par un aperçu historique et une définition précise de ces matériaux innovants. Ensuite, les différentes méthodes de préparation et de stabilisation en détail, en insistant sur les paramètres influençant leur efficacité. Les principales propriétés thermophysiques sont ensuite exposées, notamment la conductivité thermique, la viscosité, et la capacité calorifique. Enfin, les diverses applications des nanofluides dans l'industrie sont discutées, en mettant en lumière leurs avantages, mais aussi les défis et limitations associés à leur utilisation.

Ce premier chapitre constitue ainsi une base indispensable à la compréhension de la problématique de modélisation prédictive qui sera abordée dans les chapitres suivants.

I.2. Historique :

Les fluides de chauffages et climatisations sont des fluides importants dans le domaine industriel telle que le transfert de chaleur mais leurs propriétés sont peu faibles malgré que les chercheurs à utiliser des techniques pour améliorer le transfert de chaleur mais il faut trouver un moyen pour rendre ces fluides plus efficaces.

Donc depuis la publication des travaux théoriques de Maxwell il y trop longtemps, nombreuses études théoriques et expérimentales ont été menées sur la conductivité thermique des liquides contenant des particules solides en suspension. Cependant, à quelques rares exceptions près, ces recherches se sont principalement intéressées à des suspensions avec des particules de tailles millimétriques ou micrométriques.

Selon le modèle de Maxwell, la conductivité thermique effective des suspensions qui contiennent des particules sphériques s'accroît avec l'augmentation du volume occupé par les particules solides. Étant donné que le transfert thermique se produit à la surface des particules, il est recommandé d'opter pour des particules ayant un ratio surface/volume élevé. Hamilton et Crosser ont examiné les impacts d'accroître la superficie des particules en altérant leur forme pour qu'elles deviennent non sphériques, et ils ont adapté le modèle de Maxwell aux particules qui ne sont pas sphériques. Cependant, cette méthode permet généralement d'augmenter de manière expérimentale le rapport surface/volume des particules d'un facteur inférieur à un ordre de grandeur [1] .

Puis en 1995, un groupe de chercheurs de l'Université du Michigan, aux États-Unis, qui ont publié des travaux sur les propriétés thermiques des fluides contenant des nanoparticules qui à développer par le professeur **S.U.S. Choi** En d'autres termes, " les nanofluides" qui sont des suspensions colloïdales à l'échelle nanométrique contenant des nanomatériaux condensés. Ce sont des systèmes biphasés avec une phase (phase solide) dans une autre (phase liquide) [2]. Il a été constaté que les nanofluides possédaient des propriétés thermophysiques améliorées telles que la conductivité thermique, la diffusivité thermique, la viscosité et les coefficients de transfert de chaleur convectif, comparativement à ceux des fluides de base tels que l'huile ou l'eau. Ils ont démontré un grand potentiel d'application dans de nombreux domaines tels que la microélectronique, le transport, la fabrication, le chauffage et le refroidissement. [3]

Tableau I. 1 : : Les résultats obtenues par chaque chercheur depuis 1999 jusqu'à 2008 [4]

Auteurs	Année	Résultats expérimentales	
Lee et al. ; Wang et al.	1999	Montrant les fortes capacités de transfert de chaleur des nanofluides	
Xuan et Li ; Eastman et al	2000 ; 2001	Avantage des nanoparticules métalliques	
Xie et al	2001 ;2002	Importance de la taille observée	
Murshed et al.	2005	Influence de la forme	

Zhu et al	2006	Meilleure efficacité à faible fraction	
Hwang et al	2007	Comparaison entre métaux et oxydes	
Kim et al	2007	Trouvé qu'une dépendance relativement faible de la conductivité thermique à la taille des particules.	
Hong et al.	2005	Une forte augmentation de la conductivité thermique des nanofluides Fe-éthylène glycol	
Chopkar et al.	2006	Les caractéristiques très prometteuses des nanofluides métalliques,	
Das et al. ; Patel et al.	2003	Forte dépendance à la température	
Li et Peterson	2006 ; 2007	Influence de la taille, température, fraction volumique et combinaison particule/fluide	
Murshed et al.	2008	Également observé l'effet de la température pour les nanofluides aluminium-huile moteur	

Zhang et al.	2006	Aucune amélioration au-delà du modèle Hamilton–Crosser	
Zhang et al.	2007	Même conclusion	
Putnam et al.	2006	Aucune amélioration significative pour Fullerènes (C60–C70) et Au	
Venerus et al.	2006	Aucune amélioration de la conductivité thermique ou aucun effet de température pour les nanofluides or-eau et alumine-huile	
Yang et Han	2006	Aucune amélioration ni aucun effet de température pour les nanorods Bi ₂ Te ₃ de 20 nm de diamètre et 170 nm de longueur suspendus dans de l'huile ainsi que du FC72	

I.3. Définition de Nanofluide :

Le nanofluide est une combinaison de matière solide et liquide, réunissant un fluide de base et des nanoparticules dont la taille est généralement inférieure à 100nm. Les nanofluides, du fait de la petite taille et de la grande surface spécifique des nanoparticules qui sont des entités généralement mesurant entre 1 nm (10^{-9} m) et 100 nm. En étant suspendues dans un milieu liquide, les forces d'Archimède et de gravité devenant insignifiantes, les nanoparticules (NPs) se retrouvent principalement face à des collisions répétées avec les molécules du liquide,

entraînant un mouvement chaotique et aléatoire des particules. Ce phénomène est connu sous le nom de mouvement brownien, en hommage au botaniste Robert Brown qui a été le premier à observer ce mouvement sur des spores végétaux en 1827 [5] montrant des caractéristiques optimisées comme une haute conductivité thermique, un faible encombrement dans les canaux d'écoulement, une stabilité sur le long terme et une uniformité [6]. On a présenté le nanofluide comme un fluide de transfert thermique à fort potentiel, même avec les concentrations minimales possibles.

Le concept et l'émergence des nanofluides sont directement liés aux tendances de la miniaturisation et de la nanotechnologie. Le concept de Maxwell est ancien, mais ce qui est nouveau et innovant dans le concept des nanofluides, c'est l'idée que la taille des particules est d'une importance primordiale pour développer des nanofluides stables et hautement conducteurs. [7]

Les nanofluides représentent une avance prometteuse dans les secteurs industriels et technologique en particulier l'efficacité énergétique et la transition écologique pour cela les chercheurs actuelles se concentrent sur l'amélioration de leur efficacité avec la réduction des cout et l'évaluation des risque.

I.4. Fabrication des nanofluides :

Beaucoup d'expérience a été faite pour étudier les nanofluides mais ça création reste peu explorée. Les propriétés de ces nanofluides dépendent du liquide ajouté, des particules (leurs tailles, leur quantité ou leur forme) et des stabilisants ajoutés. Fabriquer des suspensions stables est une pratique ancienne. Cependant, les nanofluides doivent résister à des conditions difficiles ce qui rend leur formulation plus complexe que pour les colloïdes classiques.

Aujourd'hui, contrôler leur propriété reste un défi et pour créer ces nanofluides, deux techniques principales sont utilisées qui sont :




Figure I. 1 : schéma sur la procédure de la préparation de nanofluides. [8]

I.4.1. La méthode en deux étapes :

La méthode « en deux étapes » fait référence à l'usage de nanoparticules sous forme de poudres sèches, qu'elles soient produites en interne ou acquises prêtes à l'emploi.

Le procédé de fabrication qu'ils utilisent est essentiel : selon la technique sélectionnée, ces particules peuvent présenter différentes formes, structures et caractéristiques physiques et chimiques, ce qui aura une incidence directe sur la qualité du nanofluide produit.

Il existe actuellement plusieurs techniques pour générer ces nanoparticules, qu'elles soient issues d'un procédé mécanique, liquide ou de phase vapeur.

- Les techniques mécaniques telles que le broyage ou le meulage sont relativement faciles à appliquer, mais elles requièrent une grande quantité d'énergie.
- Les techniques liquides, telles que la méthode sol-gel ou les réactions chimiques en milieu humide, fournissent un produit précis à partir d'un nombre restreint de réactifs, mais souvent elles produisent des impuretés qui sont ardues à contrôler.
- En ce qui concerne la méthode vapeur, elle implique de générer une vapeur réactive où les particules se constituent par des procédés tels que la combustion, la pyrolyse, le plasma ou encore le dépôt chimique en phase gazeuse. Parmi toutes ces alternatives, c'est la méthode gazeuse qui se révèle être la plus bénéfique pour une production à grande échelle à la fois économiquement avantageuse et efficace en matière de qualité.

Toutefois, en raison des forces d'attraction de Van der Waals, les nanoparticules ont une propension à s'agglutiner, créant des ensembles plus volumineux que les particules individuelles. On peut clairement constater ce phénomène, par exemple avec les particules d'alumine ou de nickel. Le degré d'agglomération est influencé non seulement par la méthode de production, mais également par la manière dont les particules sont gérées et entreposées. Il est donc essentiel de sélectionner judicieusement la technique de synthèse et de caractériser attentivement les nanoparticules avant leur utilisation, afin d'élaborer des nanofluides à la fois stables et efficaces. [8]

I.4.2. La méthode en une étape :

Initialement destinée à la production de nanoparticules, avec la technique VEROS (évaporation sous vide sur un substrat d'huile en mouvement), développée par Akoh et Al. (1978) et basée sur une méthode d'évaporation directe en une seule étape, a été conçue avec cet objectif en tête.



Figure I. 2 : UP400St Homogénéisateur Ultrasonique pour la Production de Nanofluides. [9]

Cependant, l'extraction des particules du liquide pour obtenir une forme sèche demeure ardue. Pour surmonter cette contrainte, Wagener et ses collègues (1997) ont suggéré une adaptation de la technique, employant la pulvérisation cathodique magnétron à haute pression pour créer des suspensions intégrant des nanoparticules métalliques comme l'argent (Ag) et le fer (Fe). Pour leur part, Eastman et al. (1997) ont modifié la méthode en condensant directement la vapeur de cuivre (Cu) en nanoparticules lorsqu'elle est mise en contact avec un liquide ayant une faible pression de vapeur, comme le glycol.

De plus, Zhu et al. (2004) ont élaboré une technique chimique novatrice en une seule étape pour produire des nanofluides de cuivre, en réduisant le $\text{CuSO}_4 \cdot 5\text{H}_2\text{O}$ avec du $\text{NaH}_2\text{PO}_2 \cdot \text{H}_2\text{O}$ dans l'EG sous irradiation par micro-ondes. Les résultats ont révélé que l'intégration d'un agent réducteur et l'emploi de micro-ondes sont deux éléments cruciaux qui affectent non seulement la vitesse de réaction, mais aussi les caractéristiques finales des nanofluides.

Une méthode en une seule phase a l'avantage de réduire la concentration des nanoparticules. Cependant, son utilisation est limitée à des fluides ayant une faible pression de vapeur, ce qui représente sa contrainte majeure. Lo et al. (2006) ont, plus récemment, mis au point un nanofluide magnétique à base de nickel (Ni) et un nanofluide à base d'argent en utilisant la technique SANSS. Des nanoparticules d'argent de forme sphérique ont été élaborées dans du glycol éthylénique, présentant une dimension moyenne approximative de 12,5 nm. Cela donne à ce fluide un comportement semblable à celui d'un fluide newtonien [10]

I.5. Application des nanofluides :

Les nanofluides peuvent être utilisés dans diverses applications en génie d'ailleurs plusieurs études à été faites dans le domaine. Voici quelques applications des nanofluides.

I.5.1. Applications du transfert de chaleur :

- ✓ **Applications de refroidissement industriel** : Dans le secteur de l'électricité aux États-Unis, l'utilisation de nanofluides dans des systèmes de refroidissement en circuit fermé pourrait entraîner une réduction significative de la consommation d'énergie [11].
- ✓ **Extraction d'énergie géothermique et d'autres sources d'énergie** : Lors de l'extraction d'énergie à partir de la croûte terrestre, dont la profondeur varie entre 5 et 10 km et la température entre 500 °C et 1000 °C, les nanofluides peuvent être utilisés pour refroidir les tuyaux soumis à ces températures élevées [11].

I.5.2. Applications automobiles :

- ✓ **Liquide de refroidissement à base de nanofluides** : L'utilisation de nanofluides comme liquides de refroidissement constitue une innovation majeure dans le secteur du transfert thermique. Ils proposent une capacité accrue à évacuer la chaleur grâce à leurs caractéristiques thermophysiques supérieures, leur stabilité et leur flexibilité pour diverses applications, y compris le refroidissement électronique et les systèmes thermiques de pointe. La préparation par dispersion ultrasonique assure une qualité et une performance optimales, même si la gestion de l'augmentation de la viscosité demeure un facteur à surveiller pour optimiser l'efficacité totale du système.
- ✓ **Lubrifiants** : Dans les applications de lubrification automobile, des nanoparticules modifiées à la surface et dispersées de façon stable dans des huiles minérales sont efficaces pour diminuer l'usure et augmenter la capacité de charge.

I.5.3. Applications électroniques :

- ✓ **Refroidissement des microprocesseurs** : L'une des principales limites du développement de microprocesseurs plus petits est la dissipation rapide de la chaleur. Cependant, les nanofluides peuvent être utilisés pour refroidir les processeurs d'ordinateurs grâce à leur haute conductivité thermique.

- ✓ **Applications fluidiques à l'échelle microscopique :** La gestion de petits volumes de liquide est essentielle dans les dispositifs d'affichage numérique fluide, les dispositifs optiques et les systèmes micro électromécaniques (MEMS), tels que les systèmes d'analyse sur puce [12]. Les nanofluides peuvent être utilisés pour améliorer l'efficacité des panneaux solaires ou d'autres systèmes de production d'énergie.
- ✓ **Isolation électrique et équipements électrotechniques :** L'incorporation de nanoparticules dans les liquides isolants améliore les performances d'isolation sans augmenter l'épaisseur des matériaux, permettant de transporter plus de puissance dans les équipements électriques.

I.5.4. Applications biomédicales :

Les nanofluides ont également été développés pour les traitements médicaux, y compris le traitement du cancer. Les nanofluides à base de fer pourraient être utilisés pour générer des températures plus élevées autour des cellules tumorales, tuant ainsi les cellules cancéreuses sans affecter les tissus sains voisins. Les nanofluides pourraient également être utilisés pour des chirurgies plus sûres en refroidissant la zone opératoire, améliorant ainsi les chances de survie du patient et réduisant le risque de lésions organiques.

I.5.5. Défense :

Plusieurs équipements et systèmes militaires ont besoin d'un flux de refroidissement très important (de l'ordre de plusieurs dizaines de MW/m²).

À ce stade, le refroidissement à l'aide de fluides traditionnels représente un véritable challenge. Parmi les utilisations militaires, on trouve le refroidissement de l'électronique de puissance et les armes à énergie dirigée, qui requièrent des flux thermiques considérables

(500 à 1000 W/cm²). Les nanofluides ont la capacité de fournir le refroidissement requis pour ces systèmes militaires, ainsi que pour d'autres tels que les véhicules, les sous-marins et les diodes laser à haute puissance. [13]

I.6. Les nanoparticules et les fluides porteurs :

I.6.1. Les nanoparticules :

Les nanoparticules sont des particules dont la taille est de l'ordre du nanomètre (1 à 100 nanomètres). Elles possèdent des propriétés physiques, chimiques et biologiques qui diffèrent de celles des matériaux à l'échelle macroscopique en raison de leur petite taille. En raison de leur grande surface spécifique, ces particules peuvent interagir différemment avec leur environnement. Les nanoparticules sont utilisées dans divers domaines, mais leur impact potentiel sur la santé et l'environnement nécessite une étude approfondie, car leur petite taille leur permet de pénétrer plus facilement dans les cellules et d'interagir avec les systèmes biologiques de manière imprévisible. Les nanoparticules les plus utilisables :

1. Les nanoparticules d'oxydes métalliques :

a. Oxyde d'aluminium (Al_2O_3) :

L'oxyde d'aluminium a une excellente capacité diélectrique, une résistivité électrique de qualité et une bonne conductivité thermique.




Figure I. 3: digramme montre les résultats de chaque recherche donnant les valeurs maximales des conductivités thermiques obtenues par le nanofluide $\text{Al}_2\text{O}_3/\text{eau}$.

Plusieurs études expérimentales à été faites sur cette dernière en utilisant telle que :

- Lee et al ont trouvé une augmentation de conductivité de 1,4% pour une concentration de 0.01% à 0.3% et diamètre égale à 30nm [14] .
- Chandrasekar et al ont mesuré la conductivité thermique des nanofluides Al_2O_3 /eau et ont constaté une amélioration de la conductivité thermique de 9,7 % par rapport à fluide de base [3].
- Yiamsawasd et al [15] ont trouvé une augmentation de 11% pour un volume de 4% de concentration et diamètre de 120 nm pour Al_2O_3 .
- Pastoriza-Gallego a mesuré la conductivité thermique des nanofluides Al_2O_3 /EG et a observé une augmentation de la conductivité thermique de 19 % ainsi qu'un au fluide de base. [16]
- Ghanbapour et al ont montré une augmentation de conductivité de 16% à 4% pour Al_2O_3 dans un volume de 88% à 12% et diamètre égale à 75nm [17] . Puis Duan a confirmé ces résultats mais avec un diamètre inférieur qui égale à 25nm [18]. et avec la même concentration de Duan Eastman et al ont trouvé une augmentation de 24% de la conductivité pour un diamètre $d=33\text{nm}$ [19].
- En 2016, Roy Jean Issa [20] a étudié de conductivité pour Al_2O_3 /Eau pour deux tailles de particule $D_1=5\text{nm}$ et $D_2=50\text{nm}$, avec une concentration de 0 à 40% en masse est à la fin il trouve et à la fin il trouve une augmentation de K telle que : Pour D_1 l'augmentation est avec 38%, et pour D_2 l'augmentation est avec 33%.

b. Oxyde de cuivre (CuO) :

Les nanoparticules d'oxyde de cuivre sont une classe intéressante de matériaux ayant des propriétés multifonctionnelles avec des applications prometteuses dans les domaines des catalyseurs, des batteries, des supports magnétiques, de l'énergie solaire et des supraconducteurs (Frietsch et al (2000) ; Sukhorukov et al (1998) ; Carnes et Klabunde (2003) [21] .

- J. A. Eastman, S. U. S. Choi, S. Li, W. Yu, et L. J. Thompson observer Une augmentation maximale de la conductivité thermique d'environ 20 % pour des nanoparticules de CuO /EG à 4 % en volume avec un diamètre de 35 nm. [1]
- S. Li, S. U.-S. Choi, J. A. Eastman et S. Lee trouver que la conductivité augmente linéairement en fonction de volume et déclaré que in les valeurs de la conductivité thermique de CuO sont supérieures aux valeurs de Al_2O_3 . [22]

- Une autre expérience a été réalisée par Li et Paterson [5] en utilisant des nanoparticules de CuO ayant un diamètre de 29nm, dispersées dans de l'eau pure à une fraction volumique de 10% et à une température de 34,7°C. Ils ont constaté une augmentation de 52% de la conductivité thermique du nanofluide. La relation suivante est établie pour le nanofluide (eau+CuO) :

$$\frac{k_{nf} - k_f}{k_f} = 3.76108\phi + 0.017924T - 0.307$$

c. Oxyde de titane TiO₂ :

- Eastman et al. (2001) montrent que les nanofluides présentent des conductivités thermiques bien plus élevées que leur fluide de base, avec un accroissement allant jusqu'à 40 % pour un nanofluide cuivre-glycol à une concentration de 0,3 % en volume de nanoparticules. Eastman et al. (1997) ont observé un accroissement de la conductivité thermique des nanofluides pouvant atteindre 60 %, tandis que Yu et al. (2008) ont étudié divers nanofluides montrant une amélioration du transfert de chaleur dans une plage de 15 à 40 %.
- Duangthongsuk et Wongwises (2009) ont mesuré des nanofluides TiO₂-eau et ont constaté que la conductivité thermique relative des nanofluides augmente avec la concentration en volume des particules et diminue légèrement avec l'augmentation de la température. Murshed et al. (2005) montrent que la conductivité thermique des nanofluides à base de TiO₂-eau augmente de manière significative avec l'augmentation de la fraction volumétrique des nanoparticules, mais que la taille et la forme des particules peuvent également influencer l'amélioration de la conductivité thermique des nanofluides. [23]

d. Oxyde de silicium (SiO₂) :

Selon Namburu et al. (2007), une étude expérimentale a été réalisée sur la viscosité et la capacité thermique spécifique de nanoparticules de dioxyde de silicium (SiO₂) de différentes dimensions (20, 50 et 100 nm), dispersées dans un mélange d'eau et d'éthylène glycol à raison de 60 :40 en poids. Les conclusions ont conduit à déterminer un nouveau lien qui associe la viscosité au pourcentage volumique des particules et à la température du nanofluide. De plus, l'analyse des chaleurs spécifiques des nanofluides contenant du SiO₂ a été effectuée pour diverses concentrations volumiques de particules, et d'après l'expérience de Adnan M. Hussein, R.A. Bakar, K. Kadirgama and K.V. Sharma [21], Bien que les nanoparticules de TiO₂ possèdent une

conductivité thermique supérieure à celles de SiO_2 , ce dernier a montré des valeurs plus hautes de conductivité thermique à une concentration de 2,5 %, étant donné l'augmentation légèrement plus prononcée de la conductivité thermique en fonction de la concentration volumique dans le cas du nanofluide à base de SiO_2 comparé à celui à base de TiO_2 . De façon comparable, la conductivité thermique des nanofluides se renforce à mesure que la température de l'eau s'accroît.

2. Les nanoparticules métalliques :

- Aluminium (Al)
- Cuivre (Cu)
- Or (Au)
- Argent (Ag)
- Silicium (Si)




Figure I. 4 : comparaison de la conductivité thermique entre les liquides, solides et polymères [16].

3. Les nanoparticules non métalliques :

- Nanotubes de carbone (CNT)
- Diamant (C).
- Graphite.

I.6.2. Les fluides porteurs (fluide de base) :

Les liquides de base les plus utilisés sont :

- L'eau (H_2O).
- L'huile.
- Le Toluène.
- L'éthylène glycol (EG)

I.7. Les propriétés thermophysiques :

I.7.1. La conductivité thermique :

C'est la capacité de fluide à conduire la chaleur et la quantité de chaleur transféré à travers les nanofluides exprimé par watt en mètre kelvin(W/m.K)

On peut trouver dans la littérature un grand nombre d'études sur conductivité thermique (k). Pour les solutions composées de particules de taille micrométrique ou plus, Grâce au processus de diffusion thermique, en se basant sur la loi de Fourier, nous parvenons à développer des modèles dits macroscopiques.

Tableau I. 2: Conductivité thermique de divers fluides de base et martiaux à 20° [10].

Elément	Conductivité thermique λ (W/m.K)
Eau	0,599
50% eau + 50% éthylène glycol	0,41
Ethylène glycol	0,25
huile de moteur	0,14
Nanotube de carbone	3000-6000
Diamant	1000-2600
Cuivre (métal pur)	401
Nickel (métal pur)	237
Silicone (non métallique)	148
Alumine (Al_2O_3)	40

1.7.1.1. Modèles de conductivité thermique :

a. Modèle de Maxwell :

Maxwell a proposé un modèle destiné à évaluer la capacité de transfert thermique d'un nanofluide en fonction de sa fraction volumétrique de nanomatériaux. Toutefois, il est essentiel de préciser que ce modèle ne concerne que les nanofluides qui contiennent des nanoparticules

de forme sphérique. Cette contrainte peut être considérée comme une restriction du modèle, puisqu'elle limite son utilisation uniquement aux nanoparticules ayant une forme sphérique.

Le modèle de [24] a été parmi les premiers à examiner analytiquement la diffusion de la chaleur dans un liquide contenant des particules sphériques suspendues, en omettant les interrelations entre ces particules. On obtient l'équation suivante :

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

Telle que :

K_{nf} : c'est la conductivité thermique du nanofluide.

K_f : la conductivité thermique du liquide porteur.

K_s : la conductivité thermique des particules solides.

ϕ : indique la proportion volumique des particules.

b. Le modèle d'Hamilton-Crosser (1962) :

Le modèle de Hamilton et Crosser a été conçu pour surmonter les limitations du modèle de Maxwell. Étant donné que ce modèle n'est pas uniquement applicable aux particules sphériques, cela le rend inefficace pour expliquer le phénomène en question. À cet effet le modèle de Hamilton et Crosser a été conçu afin d'optimiser le calcul de la conductivité thermique d'un nanofluide, indépendamment de la forme des nanoparticules, grâce à l'introduction du facteur géométrique connu sous le nom de sphéricité (ξ). On définit ce paramètre comme étant le rapport entre la surface d'une sphère ayant un volume identique à celui des nanoparticules et la surface d'une nanoparticule elle-même.

$$\frac{K}{K_f} = \frac{\tau + (\eta - 1) - (\eta - 1)(1 - \eta)\phi}{\tau + (\eta - 1) + (1 - \tau)\phi}$$

K_f est la conductivité du fluide de base

$\tau = \frac{K_p}{K_f}$ avec K_p la conductivité des particules

ϕ : La fraction volumique des particules

Le rapport d'aspect est ici noté $\eta = \xi/3$ où ξ est la sphéricité, définie comme le rapport de la surface de la sphère de volume égal à celui de la particule sur la surface de cette dernière. Si ce modèle est tout à fait adapté aux composites dont la taille des particules est supérieure au micromètre, il n'est pas certain qu'il soit valide pour des particules de taille nanométrique. Les travaux de Keblinski et al (2002) donne preuve que plusieurs phénomènes pouvant permettre une amélioration du transfert de chaleur. Ainsi, le mouvement brownien, l'organisation de la couche interfaciale fluide/solide, le transport de chaleur balistique ou encore l'effet du regroupement des particules pourraient être des mécanismes à l'origine de l'augmentation de conductivité thermique constatée. [23].

c. Modèle de Yu et Choi :

Yu et Choi ont proposé une autre formulation pour le calcul de la conductivité thermique. Ils ont suggéré de représenter les nanofluides comme un fluide de base et des particules. Cette couche nanométrique, qui sépare les solides, sert de lien thermique entre le fluide et les nanoparticules. Par ailleurs, ils ont présumé que la conductivité thermique de la couche à l'échelle nanométrique est supérieure à celle du liquide. la relation sous la forme suivante :

$$\frac{Kn_f}{K_f} = \frac{K_s + 2K_f + 2(K_s - K_f)(1 + \beta)^3 \phi}{K_s + 2K_f - (K_s - K_f)(1 + \beta)^3 \phi}$$

Telle que :

K_f : Est la conductivité du fluide de base

β : Est le rapport de l'épaisseur de la couche nanométrique sur le rayon des particules.

d. Bhattacharya et al :

Cette relation prend en considération le mouvement brownien de particules dans des nanofluides. On peut exprimer mathématiquement le mouvement brownien comme les mouvements aléatoires des nanoparticules au sein du fluide de base.

Ce mouvement est le résultat des collisions entre les nanoparticules et les molécules du fluide de base, ces dernières se déplaçant dans toutes les directions. Elles modifient leur trajectoire en raison de l'agitation thermique. Les nanoparticules sont si petites qu'elles peuvent être déviées par des chocs, ce qui les pousse à voyager sur de brèves distances avant d'être réorientées suite à d'autres impacts, et ainsi de suite.

Ce phénomène engendre un mouvement chaotique à l'échelle mondiale, appelé mouvement brownien. La relation est sous la forme :

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

I.7.2. Chaleur spécifique (Cp) :

(Capacité thermique massique) c'est la quantité d'énergie nécessaire pour augmenter la température d'un kilogramme d'une substance d'un degré Celsius (J/kg.C°).

➤ **Les formules de la chaleur spécifique :**

- Modèle du Pak et Cho (1998) :

$$(C_p)_{nf} = (1 - \varphi)(C_p)_f + \varphi(C_p)_s$$

- Modèle du Xuan et Roetzel (2000) :

$$(\rho C_p)_{nf} = (1 - \varphi)(\rho C_p)_f + \varphi(\rho C_p)_s$$

I.7.3. Masse volumique (ρ) :

En générale c'est la quantité de matière contenue dans un volume donné qui égale à :

$$\rho_{nf} = \left(\frac{m}{v}\right)_{nf} \dots \dots (1)$$

Après la simplification (1) deviens :

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

ρ_{nf} : la masse volumique du nanofluide.

m : la masse du nanofluide.

v : le volume du nanofluide

φ_s : la masse volumique du solide (particules).

φ_f : la masse volumique du fluide de base.

I.7.4. Fraction volumique (ϕ) :

Ce paramètre détermine presque toutes les propriétés d'un nanofluide. Il s'agit d'une valeur sans dimension qui représente la proportion entre le volume des nanoparticules (partie solide) et volume total, composé des nanoparticules et de fluide de base, Cette proportion est déterminée par la formule suivante : [25]

$$\phi = \frac{V_s}{V_T} = \frac{V_s}{V_s + V_f}$$

V_s : Volume de solide (nanoparticules).

V_T : Volume totale (nanoparticules + fluide de base (V_f))




Figure I. 5 : l'effet de la fraction volumique pour le nanofluide Al_2O_3 /eau pour (150nm) [4]

I.7.5. Viscosité dynamique :

C'est le frottement interne entre les couches de fluides au mouvement, en unité de (Pas.s)

C'est une qualité indispensable pour le fluide qui est à la fois influencée et affectée par d'autres attributs. Par exemple, un liquide est considéré comme newtonien lorsque sa viscosité demeure stable à divers taux de cisaillement. Effectivement, on qualifie de non newtonien un fluide dont la viscosité change selon le niveau de cisaillement.

D'après Lee et al. (2011), dans leurs travaux, les nanofluides contiennent des particules sphériques à une fraction volumique modeste ($\phi < 3\%$), ce qui justifie le comportement newtonien observé chez les échantillons de nanofluides. [26]

Et la concentration volumique avec la taille de nanoparticule qui en relation direct avec la viscosité par contre la température est en relation inverse.




Figure I. 6 : La variation de la viscosité en fonction de champ magnétique et la fraction volumique à 30C°.




Figure I. 7 : La variation de la viscosité en fonction de champ magnétique et la fraction volumique à 40C°.

- Ces dernier figures montre que la viscosité affectée par la valeur de température et la fraction volumique. Sans oublier la conductivité thermique telle que l'augmentation de la conductivité implique l'augmentation de la viscosité.

➤ **Les formules de la viscosité :**

a. **Modèle de Einstein :**

Ce modèle proposé par Albert [27], d'écrit l'augmentation de la viscosité d'un fluide due à l'ajoute des particules sphériques rigides et espacées pour éviter les interactions et que le fluide de base doit être newtonien :

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

Où φ représente la fraction volumique des particules.

μ_{nf} , μ_f : sont la viscosité de fluide de base et la viscosité de nanofluide respectivement

Ce modèle présente des limites importantes lorsqu'il est appliqué à des systèmes réels. Notamment aux nanofluides d'une part, elle est valable que pour des très faibles concentrations volumiques inférieure à 0.01.

b. Modèle de Brinkman :

Ce modèle développé par Henrik [28], c'est une suite pour le modèle d'Einstein mais pour des concentrations modérées inférieure à 0.04, en intégrant les interactions hydrodynamiques entre les particules, ce cas est non linéaire. la viscosité de Brinkman se la forme :

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

Telle que :

- φ : représente la fraction volumique des particules
- μ_{nf} , μ_f : sont la viscosité de fluide de base et la viscosité de nanofluide respectivement

c. Modèle de Batchelor :

Ce modèle développé par [29], il a ajouté un second terme à la formule de Einstein pour prendre en compte les interactions hydrodynamiques entre particules avec une concentration inférieure à 0.02. sa formule est la suite :

$$\mu_{nf} = \mu_f(1 + 2.5 \varphi + 6.2 \varphi^2)$$

μ_{nf} , μ_f sont la viscosité de fluide de base et la viscosité de nanofluide respectivement

d. Modèle Maiga et Al :

Ce modèle a été développé par Maiga et Al [30] sa forme :

$$\frac{\mu_f}{\mu_{nf}} = (1 + a \varphi + b \varphi^2)$$

- μ_{nf} , μ_f sont la viscosité de fluide de base et la viscosité de nanofluide respectivement

- **a et b** : c'est des constantes empiriques qui dépend de nanofluide (type de nanoparticule, La taille et la forme) par exemple pour l'eau + Al₂O₃ l'équation devient sous la forme suivante :

$$\frac{\mu_f}{\mu_{nf}} = (1 + 7.3 \varphi + 123 \varphi^2)$$

Telle que a=7.3 et b=123

e. Modèle Pack et Cho :

Ce modèle est une alternative à celui de Maiga et Al il est développé en 1998, il est sous la forme suivante :

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

I.8. Types des nanofluides :

Les nanofluides peuvent être catégorisés selon la forme des nanoparticules qu'ils contiennent, cette caractéristique influençant fortement leurs propriétés thermophysiques. Du fait de leur capacité à être synthétisées et dispersées aisément, ainsi que de leur stabilité dans le milieu porteur, on peut citer deux types de nanoparticules : les nanoparticules sphériques qui sont celles qui sont généralement les plus utilisées et les nanotubes.

I.8.1. Les nanoparticules sphériques :

Les nanoparticules sphériques se définissent comme des particules nanométriques, habituellement de configuration sphérique, qui bénéficient de caractéristiques spécifiques en termes de propriétés physiques, chimiques et optiques grâce à leur taille et forme. Dans le domaine des nanosciences et des nanotechnologies, la recherche se focalise fortement sur leur synthèse, caractérisation et applications. Par exemple : l'oxyde d'aluminium (Al₂O₃), la silice (SiO₂) ou le dioxyde de titane (TiO₂).




Figure I. 8 : Image à 3D d'une nanoparticule sphérique [31]

I.8.2. Les nanotubes :

Les nanotubes sont des structures tubulaires extrêmement minces, formées d'atomes organisés selon un réseau hexagonal, essentiellement à base de carbone. Ils font partie de la catégorie des fullerènes et se composent d'un ou plusieurs plans de graphène (un réseau de carbone en forme de maillage) qui s'enroulent pour créer un tube. On peut fermer ou ouvrir ces tubes à leurs extrémités. Par exemple les nanotubes de carbone (CNT).




Figure I. 9 : nanotube de CARBONE [32]

➤ **Types de nanotubes :**

- 1- **Les nanotubes mono-feuillets (SWNT) :** constitués d'un unique feuillet de graphène enroulé. Leur configuration est déterminée par l'angle d'enroulement, connu sous le nom de chiralité, ce qui a un impact sur leurs caractéristiques électriques. Selon leur chiralité (zig-zag, chaise ou chiral), ils peuvent être de nature métallique ou semi-conductrice.
- 2- **Les nanotubes multi-feuillets (MWNT) :** constitués de multiples couches de graphène enroulées les unes sur les autres, créant ainsi des tubes concentriques [32].

I.9. Les Avantages des nanofluides :

- Amélioration du transfert thermique du fluide de travail par une élévation de sa conductivité thermique.
- Cette avancée autorise au fluide de véhiculer une quantité majorée d'énergie thermique en amplifiant sa densité et sa capacité thermique spécifique.
- Elle encourage une meilleure transmission de chaleur entre le fluide et le récepteur.
- Elle participe à l'optimisation des performances thermiques et électriques du système photovoltaïque (PV).
- En définitive, elle contribue à abaisser la température de l'absorbeur, ce qui prolonge la longévité du matériau et garantit sa sauvegarde [33].

I.10. Les Inconvénients des nanofluides :

On a constaté que, lors de l'emploi d'un nanofluide, l'érosion des surfaces et la sédimentation peuvent être jugées insignifiantes. En ce qui concerne la corrosion, elle nécessite une considération spéciale. Néanmoins, en optant pour un nanofluide chimiquement inerte ou idéalement adapté au circuit concerné, on peut éliminer ce risque. Toutefois, les nanofluides ont plusieurs désavantages, dont :

- Une disparité significative des résultats entre diverses recherches scientifiques.
- Une connaissance toujours restreinte des mécanismes théoriques qui expliquent le changement des propriétés.
- Une variabilité instable dans la distribution des nanoparticules.
- Une augmentation notable de la perte de charge pendant le pompage.
- Un coût de fabrication assez onéreux.
- Des problèmes techniques associés à la production [10].

I.11. Revue bibliographie :

Dans ce bilan bibliographique, nous exposons les résultats des recherches les plus récemment diffusées concernant les nanofluides et leurs usages.

▪ **Choi S.U.S 1995 :**

L'inventeur a forgé le concept de nanofluides (NFs) pour caractériser cette nouvelle catégorie de fluides thermiques, incorporant des particules métalliques d'une taille moyenne approximative de 10 nanomètres.

Ces nanofluides démontrent des caractéristiques supérieures comparativement aux fluides caloporteurs traditionnels. Cette recherche se focalise sur les nanomatériaux à base de cuivre, avançant que l'incorporation de ces nanoparticules pourrait aussi diminuer l'énergie requise pour les pompes des échangeurs thermiques, en raison d'une conductivité thermique améliorée. Cette étude a tracé la voie pour l'application industrielle et biomédicale des nanofluides, en particulier dans les systèmes de refroidissement à haute capacité thermique.

▪ **Eastman et Al 1996 :**

Cet article confirme la possibilité d'améliorer le transfert thermique dans des liquides tels que l'eau ou l'huile, souvent employés pour le chauffage ou le refroidissement. On insère alors de minuscules particules, connues sous le nom de nanoparticules, dans le liquide. L'emploi de nanoparticules de cuivre permet d'améliorer encore la conductivité thermique, malgré une présence minime de particules dans l'huile. Cela donne lieu à un nanofluide. [31]

▪ **Xie et Al 2002 :**

Cette étude montre que si on ajoute des nanoparticules d'oxyde d'aluminium (Al_2O_3) la conductivité thermique augmente mais cette amélioration dépend aussi de la taille des nanoparticules, de leur interaction avec le liquide, et de la conductivité thermique du liquide de départ. [32]

▪ **Lee et Choi et Eastman 1999 :**

Ces chercheurs testent deux particules qui sont l'oxyde aluminium et l'oxyde de cuivre avec une petite quantité de particules et ils ont trouvé une augmentation de conductivité thermique et aussi ils ont noté plusieurs points :

- L'éthylène glycol est plus efficace que l'eau pour augmenter la conductivité.
- Les particules de CuO présentent une efficacité supérieure à celles d' Al_2O_3 .
- L'importance de la taille des particules est indéniable : plus elles sont petites, mieux c'est.
- Ils ont également mis en parallèle leurs résultats avec un modèle théorique, cependant, ce dernier ne prédit pas de manière précise le comportement des particules de CuO . Ainsi, des recherches supplémentaires sont nécessaires, notamment pour comprendre ce qui se produit lorsque le liquide est en circulation (comme dans une conduite), car la conductivité pourrait être améliorée par le mouvement. [22]

▪ **Sarit Kumar Das 2003 :**

À une température ambiante, les nanofluides ont une meilleure capacité de conduction thermique par rapport aux liquides standards. Par conséquent, plus la température du liquide augmente, plus sa capacité à conduire la chaleur s'améliore.

Les nanofluides s'avèrent particulièrement pratiques pour le refroidissement d'appareils générant une chaleur importante, tels que les batteries ou les processeurs. La dimension des particules a une importance considérable.

Les modèles mathématiques simples que nous utilisions précédemment ne parviennent pas à rendre compte de ce phénomène. Il sera nécessaire d'élaborer des théories plus exactes, prenant en considération le mouvement aléatoire (stochastique) des nanoparticules. [4]

▪ **Hussein et al 2013 :**

Les résultats obtenus par cette étude sont que :

- La conductivité thermique s'accroît en fonction de la température et de la concentration. Le nanofluide contenant de l' Al_2O_3 est le plus efficace, puis viennent ceux à base de SiO_2 , TiO_2 , et en dernier lieu, l'eau.
- La viscosité baisse à mesure que la température monte, toutefois, elle augmente avec un nombre plus élevé de particules. Le nanofluide contenant du SiO_2 présente la viscosité la plus importante.
- Les conclusions peuvent parfois diverger d'autres recherches, en raison d'éléments tels que la dimension des particules ou la technique employée.
- Les modèles mathématiques suggérés concordent effectivement avec les résultats des expériences menées par d'autres scientifiques. [21]

I.12. Conclusion :

Les nanofluides composés de nanoparticules dispersées dans des fluides porteurs (fluide de base), ils l'ont réalisé à fabriquer ces fluides innovants quel que soit avec la méthode d'une seule étape ou deux, parce qu'ils en avaient besoin d'améliorer le transfert de chaleur et d'améliorer l'ingénierie et la gestion énergétique. Leur atout majeur est leur conductivité thermique supérieure, largement meilleure que celle des fluides traditionnels. Cela les rend prometteurs pour diverses applications comme le refroidissement dans divers domaines, les énergies, les systèmes électroniques et électrotechniques, la biomédecine ainsi que la défense.

Toutefois, malgré ces avantages prometteurs, de nombreux défis restent à relever : Durabilité à long terme, coûts de fabrication, impact environnemental et comportement complexe à l'échelle microscopique (la stabilité et l'homogénéité) pour cela les recherches futures doivent se concentrer sur l'optimisation des propriétés des nanoparticules telle que la taille, la forme et la concentration en tenant compte des propriétés des nanofluides.

En résumé, les nanofluides représentent une voie prometteuse pour les futures technologies thermiques. Cependant, l'application à grande échelle de ces mesures nécessite encore des recherches approfondies pour garantir leur efficacité, sécurité et viabilité économique.

CHAPITRE 2 :

Réseaux De Neurones Artificiels

II.1. Introduction :

Dans ce chapitre on parle sur le réseau de neurone qui est le modèle d'apprentissage automatique et son origine telle que les nombreuses recherches approfondies et riches qui a été faites sur ce concept pour mieux comprendre leur complexité avec l'essor récent du Deep Learning car il occupé une place centrale dans les innovations technologiques.

On mettra on avant les neurones biologiques car pour comprendre le principe de fonctionnement il faut débiter par les bases ou le concept comment (RN) traité l'information, Et la relation entre les nuerons biologique et les réseaux de neurone artificiel.

Ce chapitre expliquer les réseaux de neurones artificiels (RNA) qui constituent un pilier essentiel de l'intelligence artificiel contemporaine et le "machine Learning" et étudier le lien entre les réseaux de neurones et l'apprentissage automatique. Nous allons expliquer la fonction d'activation des (RNA) et les caractéristiques de chaque type telle que le développement des recherches dans cette secteur par le temps ainsi que l'architectures des RNA quelle que soit les monocouches ou multicouches qui fournissant une amplitude singulière représenter des liens complexes et non linéaires entre diverses variables.

II.2. La définition de réseau de neurone (RN) :

1. Définition :

Les réseaux de neurones constituent une technologie essentielle dans le secteur de l'intelligence artificielle. Ils fonctionnent de manière comparable au cerveau humain : ils analysent une grande quantité d'informations pour tirer des inférences. Ces appareils, constitués de « neurones » artificiels, s'auto-formulent en fonction des informations qui leur sont présentées. Cela leur offre la possibilité d'explorer des solutions concrètes dans divers domaines, comme l'identification par la voix ou la prévision de tendances. Par exemple, envisagez une application qui organise automatiquement vos courriels. Elle a été entraînée à différencier les courriels classiques de ceux indésirables, en examinant des milliers de messages pour identifier les traits distinctifs d'un courrier non sollicité.

Les réseaux de neurones occupent une place centrale dans le champ de l'apprentissage profond et de l'apprentissage automatique. Elles donnent aux machines la faculté d'identifier des motifs complexes et de faire des choix basés sur les informations. L'aptitude à l'apprentissage et à

l'adaptation autonome est essentielle pour notre nouveau programme de Data Science, dont le but est de doter les apprenants des compétences nécessaires pour exploiter cette technologie. Par exemple, dans le domaine de l'identification d'images, un réseau de neurones peut apprendre à différencier un chat d'un chien suite à une formation sur une grande série d'images labellisées.

2. Historique :

- L'idée de base des réseaux de neurones artificiels remonte à 1890, lorsque le psychologue américain W. James introduit le concept de mémoire associative. Il suggère ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connue ultérieurement sous l'appellation de loi de Hebb.



Figure II. 1: Images de W. McCulloch et W. Pitts.

- Puis en 1943 avec la présentation du Neurone Formel par W. McCulloch et W. Pitts, qui représente une abstraction du neurone physiologique. L'impact sera colossal. Avec cette présentation, ils souhaitent prouver que le cerveau fonctionne comme une machine de Turing, faisant ainsi de la pensée un processus purement matériel et logique « Plus nous apprenons sur les organismes, plus nous sommes amenés à conclure qu'ils ne sont pas simplement analogues aux machines, mais qu'ils en sont des machines. » [34]
- Quelques années plus tard, en 1949, Donald Hebb avance l'idée que les percepts et concepts sont représentés dans le cerveau par l'activation simultanée de groupes de neurones C'est la base de la loi de Hebb, qui affirme que deux neurones stimulés simultanément intensifient leur liaison synaptique. Cette perspective conteste une autre théorie qui propose que certains neurones soient spécialisés dans des fonctions cognitives sophistiquées : une notion mise en évidence par l'idée du neurone dit « Grand-mère ».

- Frank Rosenblatt a introduit le perceptron, premier modèle de neurone artificiel doté d'un système d'apprentissage supervisé en 1958. Cette démarche représente un jalon important dans l'évolution de l'intelligence artificielle. Cette initiative représente une avancée majeure dans l'évolution de l'intelligence artificielle. Durant cette période, Widrow et Hoff mettent au point l'algorithme LMS qui repose sur la modification des poids synaptiques.
- En 1969 Marvin Minsky et Seymour Papert ont dévoilé le livre *Perceptrons*, où ils analysent rigoureusement les limitations de ce modèle, notamment son incapacité à résoudre des problèmes spécifiques comme la fonction XOR.
- Bien que souvent accusé d'avoir freiné les recherches sur les réseaux neuronaux dans les années 1970, les auteurs ont toujours nié cette interprétation. Le livre a été réédité en 1980, avec des annotations manuscrites, probablement pour éviter toute accusation de modification du contenu original.
- Au début des années 1980, l'intérêt pour les réseaux neuronaux renaît avec la redécouverte de l'algorithme de rétropropagation du gradient, notamment par Rumelhart, McClelland, Parker, Hinton, et Lecun. Cet algorithme, basé sur la descente de gradient, permet aux réseaux multicouches d'apprendre efficacement à partir de données.
- En 1982, John Hop Field introduit un modèle de réseau totalement connecté basé sur la loi de Hebb, permettant de formaliser la notion d'attracteurs et de mémoire associative.
- En 1984, Teuvo Kohonen propose les cartes auto-organisatrices (SOM), un modèle non supervisé qui repose sur des mécanismes d'auto-organisation pour classer et visualiser des données.
- En 1985, apparaît la machine de Boltzmann, un autre type de réseau à attracteurs, cette fois basé sur une dynamique stochastique inspirée de Monte-Carlo, ouvrant la voie à des applications probabilistes plus complexes.
- Finalement, en 1989, Moody et Darken ont utilisé certains résultats de l'interpolation multivariable pour proposer le Réseau à Fonctions de Base Radiales (RFR), également connu sous le nom de RBF. Ce genre de réseau se démarque par sa représentation locale, il se distingue des autres variétés de réseaux de neurones [34].

II.3. Réseaux neuronaux biologiques (Soma) :

Une cellule neuronale (ou cellule nerveuse) est un type particulier de cellule biologique qui traite l'information. Il est constitué d'un corps cellulaire, ou soma, et deux sortes de ramifications arborescentes : l'axone et les dendrites.

Le corps cellulaire abrite un noyau qui renferme des informations sur les caractéristiques héréditaires, ainsi qu'un plasma qui contient l'équipement moléculaire nécessaire à la production de substances indispensables au neurone. Un neurone capte des signaux (impulsions) d'autres neurones à travers ses dendrites (récepteurs) et diffuse les signaux produits par son corps cellulaire le long de l'axone (émetteur), qui finit par se ramifier en filaments et sous-filaments. Les synapses se trouvent aux extrémités de ces filaments.

Une synapse est une structure élémentaire et une unité fonctionnelle entre deux neurones (une fibre axonale d'un neurone et une dendrite d'un autre).




Figure II. 2: le neurone biologique [35]

Lorsque l'impulsion atteint la terminaison de la synapse, certains composés connus sous le nom de neurotransmetteurs sont libérés. Les neurotransmetteurs traversent l'espace synaptique pour intensifier ou freiner, en fonction de la nature de la synapse, la propension du neurone récepteur à produire des impulsions électriques. L'efficacité de la synapse peut être modifiée par les signaux qui la traversent, permettant ainsi aux synapses d'apprendre des activités dans lesquelles elles sont impliquées. Cette dépendance à l'histoire fonctionne comme une mémoire, qui pourrait être à l'origine de la mémoire humaine.

Le cortex cérébral chez les humains est une vaste couche plane de neurones d'environ 2 à 3 millimètres d'épaisseur, avec une superficie approximative de 2 200 cm², soit presque le double de la taille d'un clavier d'ordinateur standard. Le cortex cérébral renferme près de 10⁹ neurones, ce qui équivaut approximativement au nombre d'étoiles dans la Voie lactée. Les neurones sont connectés de manière massive, bien plus complexe et dense que les réseaux

téléphoniques. Chaque neurone est relié à 10^3 à 10^4 autres neurones. En tout, le cerveau humain renferme approximativement entre 10^{14} et 10^{15} connexions.

Les neurones échangent des informations via une séquence de signaux très brève, généralement d'une durée de quelques millisecondes. Le message est modulé sur la fréquence de transmission par impulsion.

La fréquence peut varier de quelques hertz à plusieurs centaines, ce qui est un million de fois plus lent que la vitesse de commutation la plus rapide dans les circuits électroniques.

Toutefois, les décisions perceptuelles complexes comme la reconnaissance faciale sont généralement prises par les humains en quelques centaines de millisecondes. Un réseau de neurones dont la vitesse opérationnelle ne dépasse pas quelques millisecondes prend ces décisions. Cela implique que les calculs ne peuvent pas dépasser environ 100 étapes séquentielles. En d'autres termes, le cerveau utilise des processus qui s'exécutent en parallèle et comportent près de 100 étapes, afin d'accomplir des tâches liées à la perception telles que l'identification d'objets ou de sons.

Des recherches montrent aussi que la quantité d'informations échangées entre deux neurones est extrêmement faible, se résumant à quelques bits. Cela implique que les données cruciales ne sont pas communiquées de manière directe, mais plutôt disséminées à travers un large réseau de connexions. On fait souvent référence au modèle connexionniste pour décrypter le fonctionnement de certains systèmes [36].




Figure 5. Fonctionnement au niveau synaptique

Figure II. 3: Fonctionnement au niveau synaptique [37]

- a) Arrivée d'un potentiel d'action.
- b) Libération du neuromédiateur dans l'espace synaptique.
- c) Ouvertures des canaux ioniques dues au neuromédiateur.
- d) Génération d'un potentiel évoqué excitateur.

- e) Génération d'un potentiel évoqué inhibiteur. Les synapses inhibitrices empêchent la génération de potentiel d'action.
- f) Fermeture des canaux, élimination ou recapture du neuromédiateur.

II.4. Le réseau de neurone artificiel :

1) Définition :

Un réseau de neurones artificiel c'est un algorithme de classification de l'apprentissage optique de machine Learning, il peut être utilisé à la fois pour la classification ou la régression.

C'est un système informatique composé d'un ensemble de nœuds appelés "neurones" connecter entre eux. Chaque neurone artificiel composant de couche de réseau admet une entrée un nombre de connexions. Le neurone traite les entrées à partir d'une fonction mathématique introduit une sortie.

Ils ont été inspirés par le fonctionnement des neurones, qu'ils soient d'origine humaine ou animale. On optimise généralement ces réseaux par le biais de méthodes d'apprentissage statistique. Ainsi, ils se positionnent à l'intersection des méthodes statistiques et de l'intelligence artificielle, notamment lorsqu'ils ont la capacité de prendre des décisions en s'appuyant sur des données perçues. L'attrait principal des réseaux de neurones réside dans leur capacité à apprendre de l'expérience, en accord avec le « principe d'induction ». Cela signifie qu'ils sont en mesure de concevoir un système de prise de décision intégré, dont le degré d'universalité est défini par la quantité d'informations d'apprentissage en relation avec la complexité du problème à résoudre.

Grâce aux nombreuses itérations effectuées lors de l'apprentissage, les réseaux de neurones sont bien adaptés au traitement de problèmes à caractère statistique. Ils possèdent ainsi des capacités de classification et de généralisation. À l'image du cerveau biologique, un réseau de neurones se construit en renforçant les connexions (analogues aux synapses) entre ses différentes unités lorsqu'une information est apprise. Par conséquent, lorsqu'une même information est réactivée, la transmission devient plus rapide, car les connexions ont été renforcées par les activations précédentes.

Toutefois, les réseaux de neurones sont fréquemment vus comme des « boîtes noires », car ils génèrent des résultats sans nécessairement être en mesure d'expliquer clairement leur logique

d'une façon compréhensible pour un être humain. Il existe une multitude d'applications pour les réseaux de neurones dans divers domaines :

1. Algorithme de classification basé sur divers critères.
2. Dans la défense et sécurité comme guidage des missiles, reconnaissance des visages, suppression du bruit et radar.
3. La reconnaissance de formes, y compris la technologie de reconnaissance optique de caractères (OCR), est notamment utilisée par les institutions bancaires pour interpréter les montants inscrits sur les chèques.
4. Estimation de fonctions non connues.
5. Modélisation rapide de fonctions connues mais difficile à calculer avec précision, comme la décode des signaux de télédétection provenant de satellites.

Malgré tout ces avantages mais l'intelligence artificielle (IA) pose aussi des défis qui nécessitent une considération spéciale. L'un des défis majeurs réside dans le danger de biais dans les algorithmes. Ces préjugés peuvent se manifester lorsque les systèmes d'intelligence artificielle sont formés sur des données qui ne reflètent pas fidèlement l'ensemble des populations. Par exemple, des algorithmes appliqués dans le domaine médical peuvent omettre les exigences de certains groupes ethniques, conduisant à une inégalité dans les soins. Cette situation pose des questions éthiques liées à l'équité et l'accessibilité des ressources.




Figure II. 4 : Principe de fonctionnement d'un neurone artificiel [35]

2) La comparaison entre RNA et RNB :

Le réseau de neurones artificiels (RNA) est une sorte de réseau qui opère selon une approche dénommée « Feed-Forward ». Cela indique que les données se transmettent dans un sens

unique, d'un nœud à l'autre, jusqu'à parvenir au résultat final. On considère généralement que ce genre de réseau est le plus simple. Il offre de multiples atouts, y compris sa faculté d'apprendre à partir de données qu'elles soient linéaires ou non linéaires. En outre, il est particulièrement utile pour réaliser des prédictions dans le secteur financier, comme l'étude des séries temporelles. Toutefois, il présente également des désavantages. Par exemple, la structure simple rend ardue la compréhension de son mode de fonctionnement. De plus, cela repose fortement sur le matériel informatique employé.

Le Réseau de Neurones Biologique (RNB) est basé sur le modèle du cerveau humain. Il se compose de synapses, de dendrites, du corps cellulaire et d'un axone.

Dans ce mécanisme, les neurones ont pour tâche de gérer l'information. Les dendrites captent les signaux, le soma les compile, et par la suite, l'axone achemine ces signaux à d'autres cellules. Parmi ses bénéfices, il est à noter que les synapses ont une importance considérable dans le traitement de l'information en entrée. Ce genre de réseau est traiter des informations hautement complexes simultanément.

Tableau II. 1: la comparaison entre les RNB et les RNA :

Aspect	Neurone Biologique (ANB)	Neurone Artificiel (RNA)
Structure	Dendrites, soma (corps cellulaire), axone, synapses. Réseau complexe et dynamique.	Perceptron, poids synaptiques, fonction d'activation. Modèle mathématique.
Signal	Électrochimique (potentiels d'action, neurotransmetteurs). Transmission influencée par l'environnement biologique.	Numérique (valeurs pondérées). Traitement basé sur des opérations mathématiques.
Fonctionnement	Transmission du signal selon un seuil : potentiel d'action. Propagation continue.	Calcul d'une somme pondérée suivie d'une activation (sigmoïde, ReLU, etc.).
Traitement de l'information	Intégration spatiale et temporelle des signaux. Réseau neuronal hautement adaptable et flexible.	Traitement séquentiel ou parallèle selon l'architecture du réseau. Exécution déterministe pendant le processus d'inférence.
Apprentissage	Plasticité synaptique (LTP, LTD), ajustement basé sur les expériences et les stimuli	Algorithmes d'apprentissage (rétropropagation des gradients, descente de gradient).

Connectivité	Connexion dynamiques et adaptatifs basés sur l'activité neuronale et l'expérience	Connexions définies lors de l'entraînement du modèle,
Adaptabilité	Auto-organisation et régénération possible. Réactivité aux stimuli externes et internes.	Mise à jour itérative des paramètres uniquement durant l'entraînement.
Énergie et Vitesse	Très efficace énergétiquement, mais temps de réponse en millisecondes.	Traitement rapide en microsecondes, mais consommation énergétique élevée lors de l'apprentissage.

- **Machines Learning (ML) :**

Où L'apprentissage automatique c'est une branche de l'intelligence artificielle, se concentre sur le développement de modèles et d'algorithmes qui donne aux ordinateurs la capacité d'apprendre à partir des exemples et des données historiques(data), identifier les tendances et effectuer des prévisions. Pour ce faire, nous employons des méthodes telles que les arbres de décision ou les régressions.

- **Deep Learning :**

C'est une méthode d'apprentissage automatique qui repose sur l'utilisation des réseaux neurones à plus de cinq couches cachées.


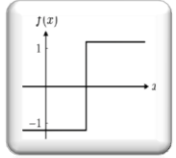
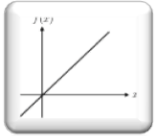

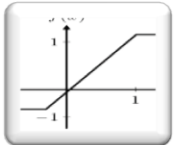
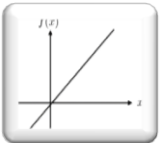
II.5. Fonction d'activation de RNA :


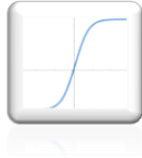
Les informations reçues par le neurone seront agrégées, et le neurone l'appliquer une fonction d'activation pour introduire une sortie. La fonction d'activation peut être caractérisée comme une fonction mathématique, aussi connue sous le nom de fonction de transfert, la fonction d'activation a pour but de convertir la somme pondérée des entrées d'un neurone en une valeur de sortie, comprend les données complexe et introduire la non linéarité au réseau de neurones. Ceci offre aux modèles la capacité d'assimiler des schémas complexes et de produire des prédictions exactes.

Pour faire simple, considérez-le comme un commutateur qui décide si un neurone doit être stimulé ou pas. Si l'entrée dépasse un certain niveau ou satisfait des critères spécifiques, le

neurone s'active/déclenche, autrement il demeure inactif donc le biais b joue un rôle essentiel en déterminant une limite : Si la somme pondérée des entrées dépasse ce seuil, l'argument de la fonction d'activation s'avère soit positif, soit nul. Par contre, si cette somme ne dépasse pas le seuil, elle est considérée comme négative.

Tableau II. 2: Les fonctions d'activation de la neutral network toolbox de Matlab :

Nom de fonction	Relation entre Entrée sortie	Nom sur Matlab	Graphes
Seuil	$F(x) = 0 \quad \text{si} \quad x < 0$ $F(x) = 1 \quad \text{si} \quad x \geq 0$	Hardlim	
Seuil symétrique	$f(x) = -1 \quad \text{si} \quad x < 0$ $f(x) = 0 \quad \text{si} \quad x \geq 0$	Hardlims	
Linéaire	$F(x) = x$	Purelin	
Linéaire saturée	$F(x) = 0 \quad \text{si} \quad x \leq 0$ $F(x) = x \quad \text{si} \quad 0 \leq x \leq 1$ $F(x) = 1 \quad \text{si} \quad x \geq 1$	Satlin	
Linéaire saturée symétrique	$f(x) = -1 \quad \text{si} \quad x < -1$ $f(x) = x \quad \text{si} \quad -1 \leq x \leq 1$ $f(x) = 1 \quad \text{si} \quad x > 1$	Satlins	
Linéaire positive	$f(x) = 0 \quad \text{si} \quad x \leq 0$ $f(x) = x \quad \text{si} \quad x \geq 0$	Poslin	

Sigmoïde	$f = \frac{1}{1+e^{-x}}$	Logsig	
Tangente hyperbolique	$f = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Tansig	

Ainsi, selon l'emplacement du résultat par rapport au seuil, le neurone pourrait être :

- **Inactif** : lorsqu'il y a une pénurie de pondération nécessaire pour dépasser la limite.
- **Pendant la phase de transition** : quand le total pondéré tend à se rapprocher du seuil.
- **Actif** : lorsque le montant pondéré dépasse la limite permise.

En incorporant des transformations non linéaires au sein du réseau, les fonctions d'activation participent à la création de limites décisionnelles plus avancées et raffinées. Cela donne lieu à une amélioration de la précision et de la capacité de prédiction.

L'efficacité du réseau de neurones à résoudre des problèmes non linéaires du monde réel est indéniablement stimulée par les fonctions d'activation. Cependant, ils ont une importance bien plus grande dans le réseau que l'ajout d'ajustements non linéaires.

Il existe plusieurs fonctions d'activation de RNA, on peut citer les sept souvent utilisés qui sont :

- **La fonction de seuil (1957) :**

La fonction seuil ou marche (step), dans le perceptron de Rosenblatt qui est la plus simple architecture de RNA, qui a plusieurs entrées et un seul neurone (une seule couche cachée + une seule sortie).

La fonction de seuil est un retour d'une fonction binaire soit 1 ou 0. cette fonction consiste à activer un neurone.

Parmi les avantages de cette fonction, elle est simple à comprendre et aussi très rapide à calculer ce qui peut être avantageux pour les systèmes réels ou les dispositifs ayant une faible puissance de calcul.

La fonction de seuil à des inconvénients par exemple lorsqu'il est utilisé dans les systèmes complexe et aussi l'absence de la dérivabilité se qui empêche leur utilisation dans les méthodes descente gradient pour l'entraînement.

- **La fonction sigmoïde et tangente hyperbolique :**

Avec le développement de Back propagation et des réseaux de neurone multicouches les fonctions sigmoïdes et tangentes hyperbolique sont devenant très populaire.

La fonction sigmoïde convertir les valeurs en un plage entre 0 et 1. permettent une activation plus granulaire.

La fonction tangente hyperbolique Tableau II.2 est une version échelonnée de la sigmoïde avec une sortie entre -1 et 1.

Dans les réseaux neuronaux, la fonction sigmoïde est couramment employée comme fonction d'activation dans la couche de sortie lors de problèmes de classification binaire. Il peut également être intégrée dans les couches cachées pour introduire la non-linéarité nécessaire dans le réseau. Ça graphe et représenté dans le Tableau II.2.

Cette fonction a des plusieurs avantage mais l'essentiel est facilité l'apprentissage des relations complexe et l'existence de ça dérivé en tous points et facile à calculer.

La sigmoïde à aussi des inconvénients tell que le problème de disparition de gradient de valich gradient lorsque les entrés devient très grandes ou bien très petit et aussi la saturation qui peut ralentir l'apprentissage, pour ces réseaux dans les application modernes de RNA d'autres fonction comme la fonction ReLU et ces variants sont souvent utiliser par les nuerons de la couche de sortie pour la classification binaire.

Généralement le comportement de la fonction tangente hyperbolique est de même avec la sigmoïde, par contre sa sortie est centrée en zéro contrairement avec la sigmoïde, cela conduire à une bonne convergence pendant l'entraînement car les poids sont s'ajuster d'un manière déséquilibres, il présente les mêmes inconvénients que la sigmoïde, il peut être utiliser dans les couches cacher ainsi que la couche de sortie pour une classification binaire.

```
x = -10:0.1:10;
y = 1 ./ (1 + exp(-x));
plot(x, y);
title('Fonction Sigmoide');
xlabel('x');
ylabel('f(x)');
grid on;
```

Figure II. 5: Exemple d'un code Matlab pour la sigmoïde pour la visualiser :

- **La fonction d'activation linéaire rectifiée (ReLU) :**

La fonction d'activation de type unité linéaire rectifiée (ReLU) est couramment utilisée dans les réseaux de neurones, en particulier dans les modèles d'apprentissage profond. En raison de sa simplicité, son efficacité et sa capacité à accélérer le traitement, il est devenu le choix par défaut dans de nombreuses architectures mais juste pour les valeurs positives. Cette fonction est une fonction linéaire qui restitue l'entrée de manière directe si elle est positive ; sinon, elle renvoie à zéro.

En d'autres termes, (ReLU) permet aux valeurs positives de rester inchangées tout en transformant toutes les valeurs négatives en zéro. Elle permet au RN de conserver la complexité nécessaire pour apprendre des motifs tout en évitant certains pièges associés à d'autres fonctions d'activation, comme le problème de la fonction. La fonction peut s'écrire sous la forme suivante :

$$f(x) = \begin{cases} x & \text{si } x > 0 \\ 0 & \text{si } x \leq 0 \end{cases}$$

Où :

- x est l'entrée du neurone.
- La fonction renvoie x si x est supérieur à 0.
- Si x est inférieur ou égal à 0, la fonction renvoie 0.

La fonction ReLU est une implémentation très simple consistant en une simple opération de seuil à zéro qui l'a rend beaucoup plus rapide à calculer qu'une sigmoïde ou $\tanh(x)$ qui nécessitent des opérations exponentielles plus coûteuses, aussi le fait que le produit de sortie nul pour les entrées négatives, il a un avantage que peu de neurones soient activés au même temps c'est pourquoi le terme d'activation soit "activation SP" cela peut améliorer l'efficacité et réduire le risque de surajustement over fit. L'utilisation de ReLU peut accélérer la convergence de l'algorithme de descente de gradient stochastique par rapport au sigmoïde au raison de sa dynamique linéaire.




Figure II. 6: graphe de la fonction ReLU :

Et parmi les inconvénients major de cette dernière est que le neurone mort car les entrées négatives de gradient de la ReLU est 0 donc les neurones qui sont dans cette phase est considérée comme morte, c'est à dire ce neurone ne se met plus à jour pendant l'entraînement cette problème connue sous le nom (dying ReLU problème).

Aussi vu que la sortie de (ReLU) est toujours positives ce qui entraine des dynamiques d'apprentissage non souhaité dans certaines ça car les poids seulement peuvent diminuer pendant l'optimisation. Les fonctions d'activation varient sont souvent utilisé dans les couches cachées.

Plusieurs variants ont été développés pour surmonter le problème et les inconvénients de ReLU comme le neurone mort et ces variants sont :

- 1) Leaky ReLU
- 2) Paramétric ReLU
- 3) Exponentiel linéaire unit ELU

```
x = -10:0.1:10;  
y = max(0, x);  
plot(x, y);  
title('Fonction ReLU');  
xlabel('x');  
ylabel('f(x)');  
grid on;
```

Figure II. 7: Un simple code pour le ReLU

- **La fonction softmax (1980) :**

La fonction softmax est une fonction d'activation largement utilisée dans l'apprentissage automatique en particulier dans le contexte de classification multi classes. Elle est dérivable et conçue pour gérer plusieurs classes, ce qui l'a rend essentiel pour la classification multi nominale.

Elle a la particularité de gérer les scores de chaque classe ou probabilité standardiser, cela très utile pour l'interprétation des sorties comme une probabilité de classe.

La fonction exponentielle utiliser dans softmax amplifier les différences entre les scores de différentes classes ce qu'il peut aider à rendre les probabilités de classe plus distinguées dans certains cas.




Figure II. 8: Le graphe de la fonction softmax

- Cette fonction a aussi des inconvénients tels que :
 - a. Calcul coûteux surtout quand les nombres de classes sont très élevés.
 - b. Sensibilité aux valeurs aberrantes

II.6. Architecture de neurone artificiel :

La structure des neurones et la façon dont ils sont interconnectés constituent les fondements d'un réseau de neurones artificiel. Elle se caractérise par le nombre d'entrées, de sorties et de nœuds, ainsi que par leur arrangement et leurs liaisons. Une des structures les plus courantes est celle en niveaux, où les nœuds d'un même niveau ne sont pas connectés entre eux directement. Ce modèle est largement utilisé dans les industries.

1) Réseau de neurone non bouclé (feed forward) :

C'est un ensemble de neurones faiblement connectés entre eux où une ou plusieurs fonctions algébriques sont étroitement réalisées de ses entrées par composition des fonctions réalisées par chacun de ses neurones, les informations circulant en un seul chemin sans retour en arrière, on peut citer des exemples comme les perceptrons et les réseaux des fonctions radiales. Il se compose de deux classes qui sont le réseau neurone multicouche et le réseau neurone monocouche [38].

A. Réseaux neurone monocouches (perceptron) :

Le réseau neurone monocouche une version basique d'un réseau de neurones artificiel qui ne comprend qu'une seule couche de neurones.

Chaque neurone dans cette couche a une connexion avec tous les autres.

Les données d'entrée, Toutefois, aucun lien direct n'est établi entre les neurones à l'intérieur de la couche. Chaque lien entre une entrée et un neurone est attribué à un poids.

Le fonctionnement d'un perceptron est assez simple. Chaque neurone effectue un calcul de somme pondérée à partir des signaux d'entrée. En se servant des poids correspondants, puis en appliquant une fonction d'activation pour générer un résultat. Ce résultat peut servir à prendre des décisions binaires, comme dans le cas de la classification binaire.

Le perceptron présente des contraintes et n'est pas apte à représenter des relations complexes non linéaires. Toutefois, il a jeté les bases pour des réseaux de neurones plus sophistiqués.




Figure II. 9: Schéma de réseau neurone monocouche (perceptron) :

B. Les réseaux neurones multicouches :

Le PMC est une version du perceptron à une seule couche qui possède une ou plusieurs couches cachées. Les neurones sont arrangés en couches successives : la première couche qui génère un vecteur de données d'entrée est désignée comme couche d'entrée, tandis que la dernière strate qui délivre les résultats se nomme couche de sortie. Toutes les autres strates situées entre celles-ci sont désignées comme étant des couches cachées .

Les neurones de la couche d'entrée ne sont reliés qu'à la couche immédiatement suivante, tandis que les neurones des couches cachées ont la particularité d'être connectés à tous les neurones de la couche précédente et de la couche suivante. Cependant, aucune connexion n'est établie entre les neurones elles-mêmes dans n'importe quel niveau.

À la différence du SLP, le P.MC, qui inclut une couche cachée, permet de modéliser plus aisément les relations non linéaires entre les données d'entrée et la sortie.

La détermination du nombre de couches cachées est souvent liée à la complexité du problème

à traiter. En théorie, une seule couche cachée pourrait être suffisante pour aborder un problème spécifique, mais il se pourrait que l'ajout de plusieurs couches cachées facilite la résolution d'un problème complexe [39].




Figure II. 10: schéma de réseau neurone multicouches :

Tableau II. 3: La différence entre les réseaux neurones monocouche et multicouches :

Type de réseau	Structure	Apprentissage	Applications
Monocouche	Une seule couche entre entrée et sortie	Classifie des données linéaires	Tâches simples (ex : décision binaire)
Multicouche	Une ou plusieurs couches cachées	Apprend des relations non linéaires	Reconnaissance d'image, NLP, prévisions

2) Réseaux neurone bouclé (feed back) :

C'est un système dynamique réalisés des fonctions différentielles. Contrairement au réseau non bouclés son graphe de connexion est acyclique donc il peut avoir des boucles qui ramène aux entrés la valeur d'une sortie ou plusieurs [38]. On peut citer quelque exemple de ce type qui est : le réseau de Hopfield et le réseau de Kohonen [40].




Figure II. 11: Schéma de neurone bouclé [38]

II.7. L'apprentissage dans les réseaux de neurones :

L'apprentissage dans les réseaux de neurones est un processus adaptatif qui permet d'ajuster les connexions synaptiques entre neurones en fonction des données reçues, s'inspirant des travaux fondamentaux de Hebb (1949), Grossberg (1982) et Rumelhart (1986). Selon Hassoum (1995).

On cite trois grandes catégories de règles d'apprentissage : supervisé, non supervisé et par renforcement. Dans l'apprentissage supervisé, le réseau apprend à associer des entrées à des sorties désirées en minimisant l'erreur, ce qui est utile pour des tâches comme la classification ou prédiction.

par contre L'apprentissage non supervisé ne repose sur aucune sortie prédéfinie ; le réseau identifie lui-même des structures ou des similarités dans les données, comme dans le clustering ou l'analyse statistique. Enfin, l'apprentissage par renforcement fournit au réseau un feedback sous forme de score (récompense ou pénalité) plutôt qu'une sortie exacte, une approche particulièrement utilisée dans les systèmes de contrôle automatique. L'objectif principal de l'apprentissage reste la classification, l'approximation de fonctions ou la prédiction de tendances futures en extrayant des régularités à partir des données. Pour y parvenir, deux principales techniques d'optimisation sont employées : la méthode du gradient, qui cherche un minimum local mais qu'il peut rester bloquée dans des solutions sous-optimales, et les approches globales, comme les algorithmes génétiques, qui évitent plus efficacement ces pièges.

L'algorithme de rétropropagation (Back propagation) est la méthode supervisée la plus répandue, notamment popularisée par des applications telles que la synthèse vocale ou la détection de fraudes. Cependant, il présente des limites, comme sa sensibilité aux minima locaux, sa lenteur et sa dépendance aux paramètres initiaux, ce qui a motivé le développement de techniques hybrides, comme les systèmes neuro-flous, pour améliorer ses performances.

comme un résumé ; l'apprentissage automatique dans les réseaux de neurones repose sur des mécanismes variés, adaptés à différents types de problèmes. Les évolutions récentes combinant l'optimisation avancée et hybridation avec d'autres approches, continuent d'élargir les possibilités de ces modèles.

II.8. Référence bibliographique :

❖ McCulloch & Pitts (1943) :

Ils ont proposé un modèle mathématique du fonctionnement des neurones qui a établi les fondations des réseaux neuronaux artificiels. Dans leur démarche, ils utilisent un neurone formel qui gère des entrées pondérées, applique un seuil d'activation et génère une sortie binaire. Ils ont démontré que les connexions neuronales peuvent être décrites par des équations logiques, facilitant ainsi la modélisation des mécanismes de pensée. Ils ouvrant la voie à l'intelligence artificielle avec cette évolution qui a guidé la conception des algorithmes d'apprentissage et des réseaux de neurones modernes. Ils ont démontré que les connexions neuronales peuvent être décrites par des équations logiques, et facilitant ainsi la modélisation des mécanismes de pensée [\[41\]](#)

❖ Rosenblatt (1958) :

Rosenblatt présente le Perceptron qui est un modèle probabiliste basé sur le fonctionnement du cerveau pour la gestion et le rangement de l'information. Il offre un système de neurones artificiels qui peuvent apprendre sur la base d'exemples et ajuster leurs liaisons en fonction des erreurs. Ce modèle a jeté les bases des réseaux neuronaux modernes et de l'apprentissage automatique. Sa méthode a eu un impact sur l'évolution des algorithmes de reconnaissance et de classification des formes [\[42\]](#).

❖ Rumelhart, Hinton et Williams (1986) :

L'article détaille l'algorithme de rétropropagation du gradient, une technique essentielle dans l'apprentissage des réseaux de neurones. Il explique comment ajuster les poids des liaisons afin de réduire l'écart entre les résultats effectifs et ceux attendus. Cette méthode offre aux neurones dissimulés du réseau la chance d'apprendre les aspects clés des données, renforçant ainsi son aptitude à généraliser. Cette recherche a transformé le domaine de l'intelligence artificielle en

améliorant l'efficacité des réseaux neuronaux pour la détection de motifs et la classification. [43]

❖ **Marvin Minsky et Seymour Papert (1969) :**

C'est une étude fondamentale sur les réseaux de neurones artificiels, en particulier les perceptrons. Publié en 1969, il analyse les capacités et les limites de ces modèles de calcul inspirés du cerveau humain. L'ouvrage a eu un impact majeur sur la recherche en intelligence artificielle, notamment en mettant en évidence les restrictions des perceptrons dans la résolution de certains problèmes, comme la fonction XOR. [44]

❖ **John Hop Field (1982) :**

Dans son article, Hopfield a démontré comment ces réseaux (réseau de Hopfield) qui un modèle de réseau de neurones récurrents qui fonctionne comme une mémoire associative, pouvaient être utilisés pour résoudre des problèmes complexes en exploitant des principes de la physique statistique. Son travail a joué un rôle clé dans la renaissance de l'intérêt pour les réseaux de neurones artificiels [45].

❖ **ECun Bengio et Hinton (2015) :**

Dans son article (Deep Learning) constitue une référence majeure dans le domaine de l'apprentissage profond. L'article étudie la manière dont les réseaux neuronaux profonds ont transformé l'intelligence artificielle en permettant aux robots d'apprendre des représentations complexes à partir de données brutes.

L'étude présente l'utilisation de réseaux convolutifs pour le traitement d'images et de réseaux récurrents pour les données séquentielles, comme le texte et la parole. Elle précise également comment la technique de rétropropagation permet d'ajuster les paramètres internes des modèles pour améliorer leur performance. [46]

II.9. Conclusion :

Les réseaux de neurones sont une révolution dans le monde de l'intelligence artificielle. Qui à été Inspirés par le fonctionnement du cerveau humain, ils nous donnent des résultats pour nous apprenons, en s'adaptant et en évoluant mais à partir des données qu'ils rencontrent. Et Grâce à des architectures et leurs mécanismes d'optimisation, ils sont capables pour la réparation des

motifs invisibles à l'œil humain, à la classification, à la prédiction et la connaissance avec une précision impressionnante.

Aujourd'hui, ces systèmes sont partout : ils analysent des images médicales, traduisent des langues, anticipent des tendances économiques et même révolutionnent notre façon d'interagir avec la technologie. En constante amélioration, ils n'ont pas fini de façonner l'avenir du numérique et notre quotidien.

On conclure que les réseaux neuronaux artificiel plus qu'une simple avancée technologique, ils redéfinissent notre façon d'interagir avec les machines et d'exploiter les données. Leur intégration dans des systèmes intelligents leur permet d'apprendre, de s'adapter et d'innover, ouvrant ainsi la voie à des applications toujours plus puissantes, allant de la reconnaissance d'images à la prise de décision autonome. En tenue compte que ces technologies évoluent, elles façonnent un avenir où l'intelligence artificielle et l'automatisation jouent un rôle central dans notre quotidien, transformant en profondeur les secteurs scientifiques énergétique, économiques et sociaux. La progression continue des RNA laisse entrevoir des possibilités infinies, rendant l'innovation non seulement fascinante, mais aussi porteuse de nouvelles perspectives pour les générations de future.

CHAPITRE 3 :

Résultat et discussion

III.1. Introduction :

Dans le premier chapitre on a mentionné que les nanofluides c'est des fluides composés des nanoparticules dispersées dans un fluide de base, qui à des propriétés thermophysiques comme la conductivity thermique, la viscosité... Qui sont différents à celles des fluides des bases ou des métaux, ces propriétés affectées par plusieurs variables qui caractérisent ces fluides comme le diamètre, la nature de fluide de base

Et pour étudier ces propriétés en fonction des facteurs quelconque, il faut une modalisation. Mais ces dernières à des comportements complexes difficiles à modéliser par des approches classiques et en plus ils prennent beaucoup de temps, et grâce à ça qu'il est préférable de choisir de faire une modélisation par la méthode de l'intelligence artificielle.

Car l'intelligence artificiel à des plusieurs application dans les nanofluides telle que : aider à modaliser des relations complexe entre les paramètres telle que le diamètre, la fraction... qui influençant sur les propriétés des nanofluides. RNA permet aussi une surveillance et une contrôle même si dans le ça où les conditions sont variables pour maximiser les performances thermiques et réduire les couts et le temps de modalisation.

Et dans ce chapitre ont va utiliser l'intelligence artificiel pour trouver les relations et les fonctions de la viscosity et la conductivity thermique qui des paramètres importants dans l'étude des nanofluides et plusieurs recherches à été dans ce concept. Cette étude a été faite pour deux type des nanofluides qui sont deux nanoparticules d'oxyde métallique qui sont AL_2O_3 et CuO dans un fluide de base qui de l'eau, pour le but de comprendre leur comportement à partir des données historiques.

III.2. Modélisation prédictive :

C'est une technique d'analyse historique où expérimentale qui utilise dans ce travail l'intelligence artificiel pour prédire les propriétés thermiques comme la conductivité et la viscosité, la compréhension des relations entre les paramètres et pour trouver les paramètres optimaux pour soit la minimisation soit la maximisation des propriétés.

III.3. Matériel et méthodes :

A. Matériels :

- Dans ce chapitre on a travaillé avec quelques logiciels qui sont :

Tableau III 1: logiciels utilisés :

Logiciel	Logo
Microsoft Excel 2013	
Web plot digitizer 4.8	
Matlab 2019	

- **Avec un ordinateur personnel de marque :** HP Pavilion g6
- **Windows :** 10 pro
- **Processor :** pentium(R) CPU B 950 2,10GHz
- **RAM :** 4 GB

B. Méthodologie de calcul :

1) Collection et préparation des données :

- En recherche sur des bases de données qui sont des résultats menés par des expériences qui ont été faites par les chercheurs.
- Préparer et arranger les données sous forme de tableaux (csv, xlsx...) pour qu'ils deviennent prêts à l'emploi.

2) Conception de modèle de réseau de neurone :

- En choisir le type de modèle (l'architecture de modèle) où on a définie le nombre de couches, neurones, fonction d'activation.....
- Validation du meilleur modèle.

3) Optimisation des architectures des RNA :

L'optimisation des architectures des réseaux de neurones à pour améliorer leur structure, où on applique un changement dans le nombre de couches, de neurones ou les fonctions utilisées. Pour mieux résoudre un problème.

4) Calcule d'erreur et choix de meilleur modèle :

En calcule l'erreur pour garantir l'utilité pratique de ce travail et bien sur que valider la performance de modèle à l'utilisation de nouveau cas :

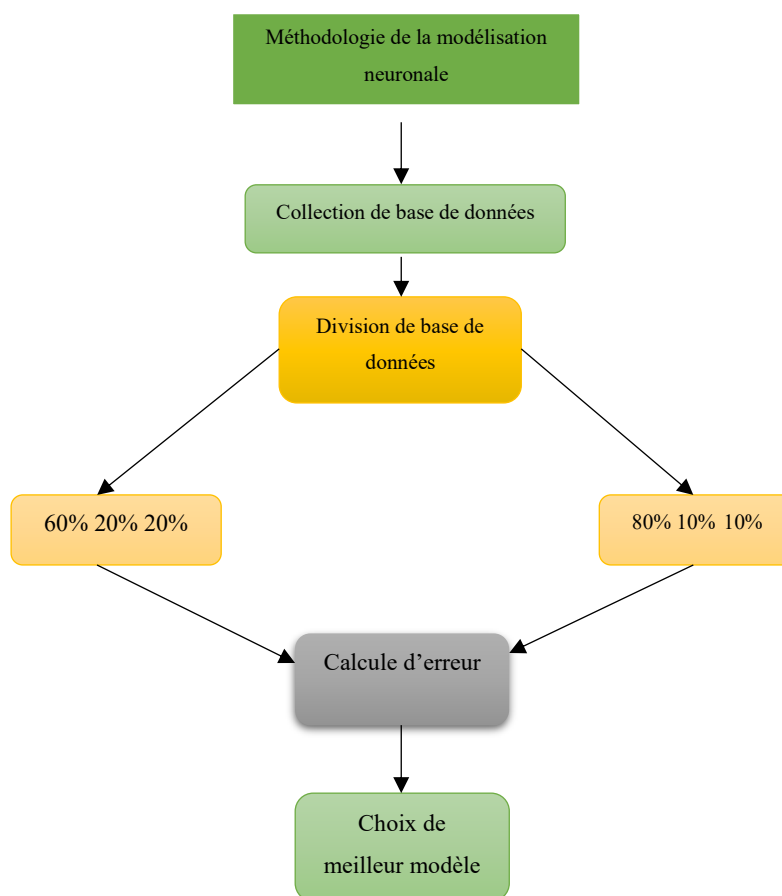


Figure III. 1: schéma de méthodologie de la modélisation neuronale :

1) Collecte de base de données :

Nous avons collecté 3533 de données extraites de la littératures scientifique les articles surtout.

Les variables d'entrées (features) sont des propriétés des nanoparticules ($\text{Al}_2\text{O}_3/\text{CuO}/\text{SiO}_2$) qui sont :

- i. Fraction volumique : θ (%)
- ii. Diamètre : $D(\text{nm})$
- iii. Température : $T(\text{K})$

Et une variable qui caractérise le fluide de base qui dans ce cas l'eau qui sont la conductivity thermique (K_{bf}) de l'eau où la viscosité de l'eau (ν_{bf}).

Les variables de sortie (Target) sont des propriétés thermiques de nanofluide soit ($\text{Al}_2\text{O}_3/\text{l'eau}$), ($\text{CuO}/\text{l'eau}$) où ($\text{SiO}_2/\text{l'eau}$), qui sont la conductivity thermique (K_{nf}) où la viscosité (ν_{nf}).

Tableau III 2: Les données des entrées et les sorties :

Propriétés	Entré (features)	Sortie (Target)
Conductivity thermique	θ [%]	K_{nf} [W/mk]
	D [nm]	
	T [K]	
	K_{bf} [W/mk]	
Viscosity	θ [%]	ν_{nf} [Pa*s]
	D [nm]	
	T [K]	
	ν_{bf} [Pa.s]	

2) Référence d'extraction des données :

On extraire les données de base par 19 références et la plupart sont des articles pour que on puisse arriver à collecter 3533 données.

Tableau III 3: Référents des données expérimentales :

			Nombre de
Nanofluides	Propriétés	Référents	données

AL₂O₃/eau	Conductivity thermique	[47] [48] [49] [50] [51] [52] [53] [54] [55] [56]	797
	Viscosité	[47] [51] [56] [10] [57] [58]	621
CuO	Conductivity thermique	[49] [50] [51] [52] [55] [56] [59] [60] [61] [62]	264
	Viscosité	[63] [64]	712
SiO₂	Conductivité thermique	[61] [57]	784
	Viscosité	[61] [57]	355

- À cause de manque de données de base dans les articles, nous nous sommes appuyés sur les diagramme suivante pour extraire les conductivity et viscosity de fluide de base (l'eau).




Figure III. 2: viscosity de l'eau en fonction de température :




Figure III. 3: conductivité thermique de l'eau en fonction de température :

3) Description détaillée des données de collecté :

Tableau III 4: Gammes de données expérimentales :

a) Conductivity thermique :

Propriétés	AL2O3	CuO	SiO2
Fraction (%)	[0.0005-20]	[0.009-20]	[1.5-7.8]
Conductivité de l'eau (W/mk)	[0.4-0.67]	[0.5-0.7]	[0.512-0.61]
Diamètre (nm)	[6.7-285]	[18-50]	[15-80]
Température (K)	[293.2-345.5]	[294-324]	[297-323.9]

b) Viscosité :

Propriétés	AL2O3	CuO	SiO2
Fraction (%)	[0.01-13]	[1-6.12]	[2.5-9.2]
Viscosité de l'eau (Pa*s)	[0.000375-0.00045]	[0.285-0.346]	[0.0005-0.928]
Diamètre (nm)	[30-100.10]	29	[15-80]
Température (K)	[323-348]	[237-323]	[279.6-336.22]

4) Division de la base de données :

Cette recherche se concentre sur deux caractéristiques importantes des nanofluides, qui sont la viscosité et la conductivité. Pour accomplir cette mission, nous recourons à deux bases de

données séparées, l'une dédiée à la viscosité et l'autre à la conductivité. Pour entraîner et tester nos modèles prédictifs, il est nécessaire de segmenter ces bases de données en groupes d'apprentissage, de test et de validation.

On a choisi deux divisions qui sont [80-10-10] et [60-20-20], pour la première division nous avons choisi une distribution de 80%, 10% et 10% pour les ensembles respectifs d'apprentissage, de test et de validation. Cela veut dire que 80% des informations concernant la viscosité et la conductivité seront destinées à l'entraînement de nos modèles : Notre modèle a été formé à l'aide de données illustratives du nanofluide, ces informations ont permis au réseau de neurones de comprendre les liens entre les différentes variables.




Figure III. 4: Graphique représente les divisions des bases de données :

Alors que 10% seront mis de côté pour juger les performances sur des données non exploitées durant l'apprentissage : l'objectif était d'évaluer sa capacité à généraliser ses prévisions.

Les 10% restants pour vérifier et perfectionner les résultats finaux du modèle.

Dans le but de trouver et choisir les meilleurs résultats de qualité et nous pouvons élaborer et évaluer des modèles prédictifs précis pour la viscosité et la conductivité des nanofluid, en segmentant nos bases de données en fonction de ces différentes proportions.

5) Optimisation des architectures des RNA :

L'optimisation des architectures des réseaux de neurones artificiels (RNA) qui a été réalisée à l'aide du logiciel MATLAB, suivant les étapes méthodiques ci-après :

- Choix de l'algorithme d'apprentissage : Nous avons opté pour l'algorithme de rétropropagation Levenberg-Marquardt, aussi connu sous le nom de trainlm (retraite Levenberg-Marquardt), dans le but de guider l'apprentissage du réseau.



Figure III. 5: Schéma des étapes de l'algorithme de Levenberg Marquardt :

- Mise en œuvre de trois fonctions d'activation différentes : en générale on a utilisé trois types de fonction d'activation qui sont (purlin,tansig et logsig).

Les fonctions purlin reste pour les couches de sortie, On a changé juste entre logsig et tansig entre l'entrés et les couches cachées de réseau de neurone.

- choisir une fonction de l'erreur : Les trois critères principaux pour La sélection du modèle optimal qui sont : l'erreur Mean Absolute Relative Différence (MAARD), le 'Mean Squared

Error” (MSE) et le coefficient de corrélation R. Ce processus suit une approche itérative de test et ajustement, visant à minimiser à la fois MAARD et MSE, tout en maximisant R.

- a. **Mean absolute absolute relative différence (MAARD)** : elle évalue la déférence relative entre les valeurs prédit par le modèle et les valeurs observées. Plus la valeur de MAARD se rapproche de zéro, plus le modèle à une précision élevée dans ses prévisions.
- b. **Mean Squared Error (MSE)** : il s'agit de l'erreur quadratique moyenne entre les valeurs prédites et les valeurs réelles. Il est plus sensible aux erreurs importantes, ce qui en fait un outil essentiel pour évaluer la stabilité et la précision du modèle. Un MSE faible signifie que les divergences entre les estimations et les données réelles sont réduites au minimum.
- c. **RMSE (Root Mean Square Error)** : C'est la racine carrée du MSE, ce qui permet de ramener l'erreur à l'unité des données et de mieux interpréter les écarts.
- d. **Coefficient de corrélation (R)** : Il indique la capacité du modèle à créer un lien entre les données d'entrée et les résultats. Quand ($R \geq 0,5$) est jugé approprié et un R se rapprochant ou égalant à 1 indique une performance prédictive supérieure.

En résumé, le choix du modèle optimal signifie la minimisation de MAARD et MSE, et en maximisant R, assurant ainsi un équilibre entre précision, fiabilité et capacité prédictive

Pour juger le modèle le plus performante on choisir la métrique de l'Erreur Absolue Relative Moyenne (MAARD).

• **Changement du nombre de neurones dans la couche cachée** : Nous avons réalisé une étude systématique sur le nombre de neurones variant de 1 à 60, afin de déterminer la configuration la plus performante.




Figure III. 6: L'une des architectures de réseau neurone utiliser :

6) Analyse des erreurs :

C'est une étape cruciale pour l'amélioration de performance de modèle RNA prédictif et comparer les valeurs réelles et les valeurs calculer de conductivité et de viscosité en identifiant les faiblesses et les améliorer.

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

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

$$R^2 = \left(\frac{\sum_{i=1}^N (y_i^{exp} - y_i^{cal})^2}{\sum_{i=1}^N (y_i^{exp} - y_i^{exp})^2} \right)$$

III.4. Résultats et discussions :

1. Résultats des architectures des modèles neuronaux obtenus :


➤ Pour la conductivité :

Tableau III 5: Résultats des architectures des modèles neuronaux obtenus pour la conductivité thermique :


	Division	Nombre de neurones	MAARD	R ²	MSE	RMSE	Fonction D'activation
A1203	[80-10 -10]	4- [20-1] - 1	Glob=0,325	Glob=0.998	3.15	Glob=0.003	Tansig
		4- [30-1] - 1	Glob=0.445	Glob=0.994	4.42	Glob=0.005	Tansig
		4- [60-1] - 1	Glob=0.384	Glob=0.999	1.82	Glob=0.004	Logsig
	[60-20-20]	4- [20-1] - 1	Glob=0.443	Glob=0.995	0.902	Glob=0.005	Tansig

		4- [30-1] - 1	Glob=0.897	Glob=0.980	0.919	Glob=0.009	Logsig
		4- [60-1] - 1	Glob=0.532	Glob=0.995	4.79	Glob=0.006	Tansig
CuO	[80-10- 10]	4- [20-1] - -1	Glob=0.596	Glob=1	1.45	Glob=0.005	Tansig
		4- [30-1] - 1	Glob=0.905	Glob=0.996	1.38	Glob=0.011	Logsig
		4- [60-1] - 1	Glob=0.870	Glob=0.997	3.48	Glob=0.010	Tansig
	[60-20- 20]	4- [20-1] - 1	Glob=0.815	Glob=0.815	2.33	Glob=0.013	Tansig
		4- [30-1] - 1	Glob=1.102	Glob=0.997	1.07	Glob=0.011	Logsig
		4- [60-1] - 1	Glob=0.707	Glob=1	2.15	Glob=0.015	Tansig
SiO ₂	[80-10- 10]	4- [20-1] - -1	Glob=0.593	Glob=0.984	0.006	Glob=2.94	Tansig
		4- [30-1] - 1	Glob=0.593	Glob=0.985	2.79	Glob=0.006	Logsig
		4- [60-1] - 1	Glob=0.586	Glob=0.986	17	Glob=0.006	Tansig
	[60-20- 20]	4- [20-1] - -1	Glob=0.497	Glob=0.999	16.3	Glob=0.006	Tansig
		4- [30-1] - 1	Glob=0.645	Glob=0.999	1.04	Glob=0.006	Logsig
		4- [60-1] - 1	Glob=0.575	Glob=0.999	2.73	Glob=0.007	Tansig


Le tableau III.5 montre que la meilleure valeur de MAARD pour la conductivité de Al_2O_3 est 0.325 est la valeur la plus proche au zéro ,pour une division de 80% pour l'apprentissage et 20% pour test et validation où la couche caché à [20-1] neurone, alors que pour la conductivité de CuO la valeur de MAARD la plus proche de zéro est 0.596 pour un division de 80% pour l'apprentissage et 20% pour test et validation avec un nombre de couche limite qui est [20-1],et pour le SiO_2 une valeur de 0.497 pour une division qui est [60-20-20] est un nombre de couches cachées qui est [20-1].



a) Al_2O_3 :



b) CuO :



c)SiO₂ :

Figure III. 7: Apprentissage de RNA pour la meilleure architecture de la conductivité de :a)AL₂O₃ ; b)CuO ; c)SiO₂ :


➤ Pour la viscosité :

Tableau III 6: Résultats des architectures des modèles neuronaux obtenus pour la viscosité :


	Division	Nombre de neurones	Maard	RMSE	MSE	R ²	Fonction D'activation
AL ₂ O ₃	[80-10-10]	4- [20-1] -1	Glob=2.223	Glob=0.996	5.09	Glob=0	Tansig
		4- [30-1] -1	Glob=1.66	Glob=0.996	3.25	Glob=0	Logsig
		4- [60-1] -1	Glob=1.949	Glob=0.996	5.28	Glob=0	Tansig
	[60-20-20]	4- [20-1] -1	Glob=1.744	Glob=0.996	10	Glob=0	Tansig
		4-[30-1]-1	Glob=1.942	Glob=0.997	29.2	Glob=0	Logsig
		4-[60-1]-1	Glob=1.624	Glob=0.997	4.54	Glob=0	Tansig
CuO	[80-10-10]	4- [20-1]-1	Glob=0.001	Glob=1	7.29	Glob=0.001	Tansig
		4- [30-1]-1	Glob=0	Glob=1	1.31	Glob=0.001	Logsig

		4- [60-1]-1	Glob=0.001	Glob=1	9.41	Glob=0	Tansig
	[60-20-20]	4- [20-1]-1	Glob=0.001	Glob=0.999	5.86	Glob=0.001	Tansig
		4- [30-1]-1	Glob=0.001	Glob=1	4.72	Glob=0.003	Logsig
		4- [60-1]-1	Glob=0.001	Glob=1	6.7	Glob=0.001	Tansig
SiO ₂	[80-10-10]	4- [20-1]-1	Glob=0.497	Glob=0.998	10.1	Glob=0	Tansig
		4- [30-1]-1	Glob=0.645	Glob=0.999	21.3	Glob=0	Logsig
		4- [60-1]-1	Glob=0.575	Glob=0.999	11.1	Glob=0	Tansig
	[60-20-20]	4- [20-1]-1	Glob=0.605	Glob=0.999	2.59	Glob=0	Tansig
		4- [30-1]-1	Glob=0.657	Glob=0.999	13.2	Glob=0	Logsig
		4- [60-1]-1	Glob=0.586	Glob=0.999	3.68	Glob=0	Tansig


Le tableau III.6 montre que la meilleure valeur de MAARD pour la viscosity de AL₂O₃ est 1.66 pour la division 80% pour l'apprentissage et 20% pour test et validation où la couche caché à [30-1] neurone, alors que pour la conductivité de CuO la valeur de MAARD est 0 pour un division de 80% pour l'apprentissage et 20% pour test et validation avec un nombre de couche limite qui est [30-1] et cette valeur c'est la plus excellent, et pour le SiO₂ une valeur de 0.497 pour une division qui est [80-10-10] est un nombre de couches cachées qui est [20-1].



a) AL_2O_3 :



b) CuO :



c) SiO_2 :

Figure III. 8: Apprentissage de RNA pour la meilleure architecture pour la viscosité de AL_2O_3 , CuO et SiO_2 :

2. Les architecture les plus performantes :

D'après les résultats qui on a obtenue dans le Tableau III 5et Tableau III 6et après la comparaison entre les valeurs de MAARD on a remarqué que les architecture les plus performantes sont les suivants :

Tableau III 7: les architecture les plus performantes :

➤ Pour la conductivité :

	Division	N.N.CC	MAARD	R ²	Fonction.A.CC
Al₂O₃	[80-10-10]	[20-1]	0.325	0.998	Tansig
CuO	[80-10-10]	[20-1]	0.596	1.000	Tansig
SiO₂	[80-10-10]	[60-1]	0.497	0.986	Tansig

➤ **Pour la viscosité :**



	Division	N.N.CC	MAARD	R ²	Fonction.A.CC
Al₂O₃	[80-10-10]	[30-1]	1.66	0.996	Logsig
CuO	[80-10-10]	[30-1]	0	1.00	Logsig
SiO₂	[80-10-10]	[20-1]	0.497	0.998	Tansig

Dans c'est architecture on a trouvé des valeurs de MAARD proche à la valeur parfaite qui est zéro et un coefficient de corrélation qui proche de 1 et supérieure à 0.9 donc en conclure que ces des valeurs proches à la perfection et ces modèles offre des excellentes précisions pour les deux paramètres :la viscosité et la conductivité, et en générale des performances stable pour les valeurs de test et de validation.


Les petites valeurs de l'erreur peuvent être à cause de la qualité de base de données, l'optimisation de modèle ou le choix de fonction d'activation.

On à vue que même si la base de données c'est la même mais quant on a modifié dans l'architecture soit dans les divisions ou le nombre de neurone dans la couche cachée les valeurs des erreurs change donc ces facteurs influence sur la modélisation prédictive.


3. La comparaison graphique des résultats obtenue :




Conductivité de CuO




Conductivité AL2O3



Conductivité SiO2



Viscosité SiO2



Viscosité Al2O3

Viscosité CuO


Figure III. 9: Comparaison graphique entre les valeurs expérimentales et calculer a base globale :

Où "Outputs" c'est les valeurs générées par le modèle et "Target" c'est les valeurs théoriques.

D'après les graphes de la Figure III.9 les graphes des valeurs expérimentales sont presque identiques avec la diagonale $X=Y$ de modèle, ce qui signifie que ces modèles sont capables à prédire bien les valeurs expérimentales pour notre étude qui sont la conductivité thermique et la viscosité des nanofluides, ce qui montre la faible valeur de MAARD proche de zéro et une valeur de R^2 très proche à 1 qui implique une performance élevée.


On a extrait des graphes des conductivité et viscosité expérimentale et calculer par le réseau de neurone. Pour les comparer en fonction de fraction et température et diamètre dépend de données de base qu'on a.

a) AL_2O_3 :




b) CuO

Figure III. 10: Graphe de conductivity calculer et expérimentale en fonction de fraction pour AL_2O_3 et CuO :




: a) AL_2O_3




b) SiO_2 :

Figure III. 11: Graphe de conductivity calculer et expérimentale en fonction de température

pour AL₂O₃ et SiO₂ :



a) fraction



b) diamètre

Figure III. 12: Graphe de viscosité calculer et expérimentale pour AL₂O₃ en fonction de :




Figure III. 13: Graphe de viscosité calculer et expérimentale pour CuO en fonction de température :





Figure III. 14: Graphe de viscosité calculer et expérimentale pour SiO₂ en fonction de

température :

Ces graphes des valeurs expérimentales nous permettent de prédire les propriétés quel que soit les matériaux et raisonner les relations complexe entre les paramètres, et la comparaison graphique entre les valeurs calculer et les valeurs expérimentales nous permet d'augmenter la stabilité, la robustesse et la précision de modèle.

- la fonction de modèle s'extraire de la façon suivante :

Figure III.10: Schéma de réseau de neurone :



$$S1 = \sum_{i=1}^4 f1(w_i.x_i + b_i)$$

$$S2 = \sum_{j=1}^N f1(w_j.S1_j + b_j)$$

$$Y = \sum_{k=1}^1 f2(w_k.S2_k + b_k)$$

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

N : est le nombre de neurones dans la couche cachée.

1 : est le nombre de couche de sortie.

W et b sont les points et les biais sous forme de matrice.

$f1$: c'est la fonction d'activation (tansig où logsig).

$f2$: C'est la fonction d'activation 'purlin'.

III.5. Conclusion :

On est arrivé à faire un modèle capable de prédire avec précision la conductivité thermique et la viscosité d'un nanofluide composé d' Al_2O_3 , SiO_2 et de CuO . On a suivi une méthodologie qui a été bien structurée, on commence par la collection de données puis division des données en trois phases principales : apprentissage pour comprendre les relations entre les entrées à partir des données, test pour vérifier sa capacité à prédire et validation pour évaluer sa précision et sa robustesse du modèle.

Après que le modèle prête Nous nous sommes appuyés sur trois type fonctions d'erreur pour évaluer la qualité de prédiction, la précision et la robustesse qui sont les MAARD dans le premier degré puis le coefficient de détermination R^2 et RMSE.

Après la comparaison qu'on a faite on choisit les architectures les plus performantes pour chaque nanofluide pour chaque propriété thermophysiques, pour la conductivité de Al_2O_3 la meilleure valeur modélisation est celle de la division [80-10-10] avec un nombre de couche cachée qui est [20-1], pour la conductivité de CuO avec une division [80-10-10] avec un nombre de C.C [20-1] et pour la conductivité de SiO_2 avec les paramètres : [80-10-10], [60-1].

A propos de la viscosité, les meilleurs architectures sont : pour Al_2O_3 et CuO est celle de la division [80-10-10] et avec un nombre de C.C qui est [30-1], et SiO_2 est celle de la division [80-10-10] et de nombre de C.C [20-1].

En générale on a trouvé des valeurs d'erreur considéré comme faible se qui prouver que les réseaux de nuerons artificielles offrent une approche qui est performante et efficace qui dépend de plusieurs facteurs telle que type de nanofluide, la qualité des données, les divisions et le nombre de couches cachées. Cette approche ouvre une voie à plusieurs applications et recherches profond dans le domaine de la science et ingénierie.

Conclusion générale :

Dans cette étude nous sommes penchés sur les nanofluides qui sont un mélange d'un fluide de base qui est de l'eau et les nanoparticules, ces dernières permettent une amélioration de l'efficacité des systèmes de transfert de chaleur donc une conductivité thermique élevée et bien sûr un rendement accru, mais il reste que il y'a quelques défis face aux ingénieurs comme la stabilité et les coûts élevés qui nécessitent des contrôles des propriétés de ce mélange complexe, et dans ce travail on a choisi de faire la modélisation prédictive avec l'intelligence artificielle.

On a utilisé cette méthode car elle est capable de prédire les propriétés qui sont : la conductivité et la viscosité pour les trois nanoparticules Al_2O_3 , SiO_2 et CuO dispersées dans l'eau, pour obtenir un meilleur modèle avec précision et robuste et raisonner les relations complexes entre ces paramètres ainsi que préserver les coûts et les énergies thermiques.

Dans ce travail on a suivi une démarche méthodologique complète et nous nous sommes appuyés sur la fonction d'erreur qui est le MAARD pour évaluer l'efficacité du modèle grâce à sa précision, et choisir la meilleure architecture. Et à la fin on l'a trouvé ce qui nous permet de dire que les réseaux de neurone sont capables de prédire la conductivité thermique et la viscosité.

Donc la modélisation avec l'intelligence artificielle nous permet une approche méthodologiquement innovante pour dépasser les limites des modèles théoriques classiques, qui est plus dynamique et adaptée à la complexité des interactions dans les nanofluides, cette rupture permet un meilleur contrôle pour les phénomènes émergents, et une amélioration dans la précision des prédictions thermophysiques. Enfin cette approche ouvre toujours la voie à des améliorations pour l'optimisation des performances thermiques.

Bibliographie :

- [1] J. A. Eastman, S. U. S. Choi, S. Li, W. Yu et L. J. Thompson, «Anomalous increase in effective thermal conductivities of ethylene glycol-based nanofluids containing copper nanoparticles Available to Purchase», pp. 718-720, 2001.
- [2] H. M. e. al, «new temperature dependent thermal conductivity data for water-based nanofluids», pp. 363-371, 2009.
- [3] A. Manimaran, «. Preparation and characterization of copper oxide nanofluid for heat transfer applications. Appl Nanosci 4,,» pp. 163-167, 2014.
- [4] H.E. Patel, « An experimental investigation into the thermal conductivity enhancement in oxide and metallic nanofluids», p. 1015–1031, 2010.
- [5] G. Peterson., «Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids», Journal of Applied Physics, 2006.
- [6] Chandrasekar, M., Suresh, S., Chandra Bose, A.,, «Expérimentale investigations and théorétiqueal determination of thermale conductivity and viscosity of Al₂O₃/water nanofluid», 2010.
- [7] Sarit K. Das, «.Nanofluids: Science and Technology,,» p. 5, 2007.
- [8] D Wen, «Particuology», Elsevier, 2009.
- [9] A. K. J. M. & M. K. M. Jain, « Artificial neural networks», pp. 31-44, 1996.
- [10] S. Halelfadl, «Characterization of the thermo-physical and heat exchange properties of carbon nanotube-based nanofluid», . Mechanical Engineering [physics.class-ph], 2014.
- [11] E. & I. T. «Nano-fluids and its Applications. International Journal of Scientific Research in Science, Engineering and Technology», 2020.
- [12] A. Journals, «Nanofluids and Its Applications.,» 2015.
- [13] H. E. HARFI, toubkal.imist.m, 2013.
- [14] .. L. e. al., «Effective viscosities and thermal conductivities of aqueous nanofluids containing low volume concentrations of AL₂O₃ nanoparticles,,» pp. 2651-2656, , 2008.

- [15] T. Y. e. al, «Measurement of the thermal conductivity of titania and alumina nanofluids,» pp. 48-56, 2012.
- [16] Wen, « Review of Nanofluids for Heat Transfer Applications , Particuology, 7200,» 2009.
- [17] M. G. e. al., «Thermal properties and rheological behaviour of water based AL₂O₃ nanofluid as a heat transfer fluid,» pp. 227-235, 2014.
- [18] F. Duan, «Thermal property measurement of AL₂O₃-water nanofluids,» pp. 335-357, 2012.
- [19] J. E. e. al., «Enhanced thermal conductivity through the development of nanofluids,» pp. 3-11, 1997.
- [20] R. J. Issa, «Effect of Nanoparticles Size and Concentration on Thermal and Rheological Properties of AL₂O₃-Water Nanofluids,» 2016.
- [21] M. Engineering., «Experimental Measurement of Nanofluids Thermal Properties,» 2013.
- [22] S. e. a. Lee, «Measuring thermal conductivity of fluids containing oxide nanopa,» . Journal of Heat transfer, pp. 280-289, 1999.
- [23] O. D. O. S. Jean-Antoine Gruss, «A new technology for heat exchanges: Nanofluids,» 2007.
- [24] J. Maxwell, « A Treatise on electricity and magnetism,,» Clarendon Press, 1891.
- [25] D. Bruggeman., « Ann,» Ann. Physics (Leipzig), 1935.
- [26] A. & P. A. Malekzadeh, «Experimental Investigations on the Viscosity of Magnetic Nanofluids under the Influence of Temperature, Volume Fractions of Nanoparticles and External Magnetic,» p. 693–697 , 2016.
- [27] A. Einstein., «Investigations on the Theory of the Brownian Movement. Dover Publications,» 1956.
- [28] H. C. Brinkman, «. The viscosity of concentrated suspensions and solutions,» The Journal of Chemical Physics, pp. 571-571, 1952.
- [29] G. Batchelor, «Brownian diffusion of particles with hydrodynamic interaction,» Journal of Fluid Mechanics, pp. 1-29, 1976.
- [30] S. E. B. P. S. J. N. C. T. R. G. G. N. Maiga, «Heat transfer enhancement by using nanofluids in forced convection flows,» nternational journal of heat and fluid flow, pp. 530-546, 2005.

- [31] J. C. U. L. S. e. a. E. T. C. t. t. D. o. N. M. O. P. L. 4. 3. (.] Eastman, «Enhanced Thermal Conductivity through the Development of Nanofluids,» MRS Online Proceedings Library 457, 1996, pp. 3-11.
- [32] Huaqing Xie, Jinchang Wang, Tonggeng Xi, Yan Liu, Fei Ai and Qingren Wu, «thermal conductivity enhancement of suspensions containing nanosized alumina particles,» APPLIED PHYSICS, 2002.
- [33] B. Noura, Etude des propriétés thermiques des nano fluides appliquées, UNIVERSITÉ IBN-KHALDOUN - TIARET-, 2020.
- [34] F. k. TRINH, SIMULATION D'UN RESEAU DE NEURONES, UNIVERSITÉ DE SHERBROOKE , 2010.
- [35] K. (. Suzuki, Artificial Neural Networks - Methodological Advances and Biomedical Applications, 2011.
- [36] A. K. J. M. & M. K. M. Jain, «. Artificial neural networks: a tutorial.,» pp. 31-44, 1996.
- [37] C. Touzet, « Les réseaux de neurones artificiels,» 1992.
- [38] Y. Djeriri, « Les Réseaux de Neurones Artificiels,» 2017.
- [39] E. M. Brakni, Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM, Université du Québec en Abitibi-Témiscamingue, 2011.
- [40] L. M. M. A. Sarab M. Hameed, Utilizing Hopfield Neural Network for Pseudo-Random Number Generator, 2018.
- [41] M. & Pitts, «A logical calculus of the ideas immanent in nervous activity.,» The Bulletin of Mathematical Biophysics,, pp. , 115-133, 1943.
- [42] F. Rosenblatt, «The perceptron: A probabilistic model for information storage and organization in the brain,» Psychological Review, pp. 386-408, (1958).
- [43] H. & (. L. r. b. b.-p. e. N. 3. 5.-5. Rumelhart, « Learning representations by back-propagating errors.,» Nature, 323(6088), pp. 533-536, 1986.
- [44] M. L. M. a. S. A. Papert, «Perceptrons.,» 1969.
- [45] .. J. Hopfield, «Neural networks and physical systems with emergent collective computational abilities,» Proceedings of the National Academy of Sciences, p. 2554–2558, 1982.
- [46] e. B. & Hinton, «Deep learning,» Nature, 521(7553), pp. 436-444, 2015.

- [47] A. E. K. T. a. N. H. H. Masuda, «“Alteration of Thermal Conductivity and Viscosity of Liquid by Dispersing Ultra-Fine Particles,» Netsu Bussei, vol. 7, n° %14, 1993.
- [48] S. C. S. L. L. T. a. S. L. E. t. c. t. t. d. o. n. M. R. S. S. P. J.A. Eastman, «Enhanced thermal conductivity through the development of nanofluids,» Materials Research Society Symposium Proceedings, Materials Research Society, Pittsburgh, vol. 457, p. 311, 1997.
- [49] X. X. a. S. C. X.W. Wang, «Thermal conductivity of nanoparticlefluid mixture,» Journal of Thermophysic and Heat Transfer,, vol. 13(4): 474480, 1999.
- [50] N. P. P. T. a. W. R. S.K. Das, « Temperature depended of thermal conductivity enhancement for nanofluids,» Journal of Heat transfer transaction of the ASME,, vol. 125(4): 567574, 2003.
- [51] A. Journals, « “Nanofluids and Its Applications,» Allied Journals, 2015.
- [52] S. C. S. U. L. S. a. E. Lee, «Measuring Thermal Conductivity of Fluids Containing Oxide Nanoparticles,» ASME. J. Heat Transfer, pp. 280-289, May 1, 1999.
- [53] S. B. P. P. P. E. e. a. Krishnamurthy, « Enhanced mass transport in nanofluids,» Nano letters, vol. 6, n° %13, pp. 419-423.
- [54] E. R. M.] L.S. Sundar, «Thermal conductivity and viscosity of stabilized ethylene glycol and water mixture Al₂O₃ nanofluids for heat transfer applications: an experimental study,» Heat Mass Transf., p. 86–95., 2014.
- [55] K. K. C.H. Chon, «Thermal conductivity enhancement of nanofluids by Brownian motion,» J.Heat Transfer 127, p. 810, 2005.
- [56] G. R. C. T. N. a. D. D. H. A. Mintsa, «New temperature dependent thermal conductivity data for water-based nanofluids,» International Journal of Thermal Sciences, vol. 48, n° %12, pp. 363-371, Feb.2009.
- [57] Z. S. M. H. A. M. A. e. a. SAID, « Experimental investigation of the thermophysical properties of AL₂O₃-nanofluid and its effect on a flat plate solar collector,» International communications in heat and mass transfer, vol. 48, 2013.
- [58] C. T. D. F. R. G. e. a. Nguyen, «Temperature and particle-size dependent viscosity data for water-based nanofluids–hysteresis phenomenon.,» international journal of heat and fluid flow, vol. 28, n° %16, pp. . 1492-1506., 2007.
- [59] H. H. D. M. Z. e. a. Zhu, «Preparation and thermal conductivity of CuO nanofluid via a wet chemical method,» 2011.

- [60] «_Rheological_behaviour_of_ethylene_glycol_based_titania_nanofluids,» [En ligne]. Available: <https://www.researchgate.net/publication/229230440>.
- [61] V. P. A. & T. P. J. B. Nair, « Water-based Al₂O₃, CuO and TiO₂ nanofluids as secondary fluids for refrigeration systems: a thermal conductivity study,» p. 262, 2018.
- [62] A. Aminian, « Predicting the effective thermal conductivity of nanofluids for intensification of heat transfer using artificial neural network,» Powder Technol, pp. 288–309,, 2016.
- [63] P. K. K. D. P. M. D. & D. D. K. Namburu, «Viscosity of copper oxide nanoparticles dispersed in ethylene glycol and water mixture,» . Experimental Thermal and Fluid Science, pp. 397-402, 2007.
- [64] A. H. S. Z. M. N. S.-N. M. & H. A. A.] Kazemi-Beydokhti, «EXPERIMENTAL INVESTIGATION OF PARAMETERS AFFECTING NANOFLUID EFFECTIVE THERMAL CONDUCTIVITY,» Chemical Engineering Communications, p. 593, (2014)..
- [65] 2. F. Salma Halelfadl. Characterization of the thermo-physical and heat exchange properties of carbon nanotube-based nanofluids. Mechanical Engineering [physics.class-ph]. INSA de Rennes, «Characterization of the thermo-physical and heat exchange properties of carbon nanotube-based nanofluids,» Mechanical Engineering [physics.class-ph], 2014.
- [66] M. S. S. C. B. A. Chandrasekar, «experimentale investigation and theorique determination of thermale conductivity and viscosity of al₂o₃/water nanofluide,experimentale thermale and fluid Sciences34,» p. 210, 2010.