

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 Guelma



Faculté des Sciences et de la Technologie
Département de génie des procédés
Laboratoire d'analyse industrielle et de génie des matériaux - LAIGM

THÈSE
EN VUE DE L'OBTENTION DU DIPLOME DE
DOCTORAT EN 3^{ème} CYCLE

Domaine : Sciences et Techniques Filière : Génie des procédés
Spécialité : Génie des procédés

Présentée par

GRINE Wassila

Intitulée

**Modèles prédictifs de la conductivité thermique des nanoparticules pour
simulation des nanofluides**

Soutenue le : .../.../2021

Devant le Jury composé de :

Nom et Prénom

Grade

Mr. NEMAMCHA Abderrafik
Mr. BENHAMZA M.E. Hocine
Mr. BAHI Lakhdar
Mr. BRIMA Abdelhafid

Prof.	Univ. de 8 Mai 1945 Guelma	Président
Prof.	Univ. de 8 Mai 1945 Guelma	Encadreur
Prof.	Univ. de Constantine I	Examineur
Prof.	Univ. de Batna 2	Examineur

Année Universitaire : 2020 - 2021

Enfin, nous y voilà ! Quelle aventure ...

Une thèse, c'est un travail de longue haleine, un défi que l'on se lance à soi-même. Mais c'est surtout une formidable histoire de relations, de rencontres et d'amitié. La pratique de la recherche scientifique vous place souvent face à des questionnements intellectuels et à des obstacles techniques car les solutions, rarement simples et directes, n'ont jamais été trouvées en un claquement de doigts. En effet, elles se sont imposées par le fruit des nombreux contacts que j'ai eu l'occasion de créer avec nombre de personnes passionnées par leur projet et par leurs spécialités.

Cette période de doctorat aura été probablement l'un des plus beaux chapitres de ma vie. J'aimerais remercier ceux et celles qui d'une manière ou d'une autre, ont participé à son aboutissement

Al hamdoulillah.

Wassila Grine

Dédicaces



*A mes parents qui j'aime beaucoup, et qui sont mes
plus chers.*

A mes chers frères

A ma sœur bien aimée

A toute ma famille sans exception.

A mes chères amies



Remerciements

*J'aimerais bien évidemment débiter cette page en remerciant **ALLAH** le tout Puissant qui m'a donné la force, le courage et la patience de bien mener ce travail qui a été réalisé au sein de laboratoire d'Analyses Industrielles et Génie des Matériaux de l'université de Guelma.*

*Un remerciement spécial à mon encadreur le **Pr. Mohamed El Hocine BENHAMZA**. Je ne serais jamais le remercier assez pour la confiance qu'il m'a accordée durant ce travail. Je le remercie aussi pour son aide précieuse, ces conseils judicieux, sa patience et surtout pour toutes les heures qu'il a consacrées à diriger cette recherche de manière perfectionnée et minutieuse.*

*Je remercie le professeur **Mr. NEMAMCHA Abderrafik** qui m'a fait l'honneur de présider le Jury de cette thèse. Je suis reconnaissante à Monsieur le professeur **BAHI Lakhdar** et Monsieur le professeur **BRIMA A. Hafid** d'avoir bien voulu participer au jury de soutenance. Je leur exprime ma gratitude pour le temps consacré à lire et à juger mon travail.*

*Je remercie aussi tous les membres du (LAIGM) surtout Monsieur le directeur le professeur **M.E.H BENHAMZA** et l'ingénieure de laboratoire Madame **Houda BOUKHEDNA**, pour leurs aides.*

*Je tiens à remercier toutes les personnes qui m'ont aidée pour la réalisation de ce travail, et particulièrement Monsieur **Seif Eddine Chehaidia** Docteur à l'université d'Annaba ; mes remerciements vont aussi à Monsieur **Mohamed Elghazali Benhamza** Docteur à l'université de Biskra pour l'aide qu'il m'a prodigué lors de la préparation de ma publication. Je témoigne ma profonde gratitude à ma chère sœur **Hadjadji Narimane** Docteur à l'université de*

*Guelma pour tous les très chers et beaux moments qu'on a passé ensemble, et aussi pour son soutien continu ; aussi un tout grand merci à ma chère amie **Khaoula Bekkar** Docteur à l'université de Guelma pour son aide, ses encouragements et sa disponibilité. J'exprime mes remerciements également, à monsieur **bencharef sofiane** pour ses conseils en traduction et correction linguistique.*

*J'exprime une reconnaissance toute particulière à ma source de tendresse « **mes parents** ». Ces deux êtres qui ont su m'éduquer, qui étaient toujours derrière moi et qui m'ont poussé à aller de l'avant. Sans vous deux, je n'aurais jamais pu aller jusqu'au bout. Chers parents veuillez accepter mes sentiments les plus profonds.*

Mes remerciements les plus vifs vont également à ma chère sœur et mes chers frères, pour leurs encouragements et leurs soutiens, souvent discrets, mais toujours efficaces.

Un merci du cœur à tous mes amis qui m'ont supporté dans les bons comme dans les mauvais moments tout au long de cette thèse, merci à ceux que je n'ai pas cités mais qui m'ont encouragée quotidiennement, par quelques mots ou un sourire.

Mille pardons pour l'insuffisance des mots et mille excuses pour tous les oubliés.

« Celui qui n'a pas remercié les gens n'a pas remercié Dieu »

MERCI, à tous !

Résumé

Les nanofluides ont récemment été considérés comme l'un des fluides de travail les plus populaires en transfert de chaleur et en mécanique des fluides. Une estimation précise des propriétés thermophysiques des nanofluides est nécessaire pour l'étude de leurs performances en transfert de chaleur. Le coefficient de conductivité thermique et la viscosité sont quelques-unes des propriétés thermophysiques les plus importantes qui influencent directement l'application des nanofluides.

Une telle augmentation de la conductivité thermique du nanofluide ne peut pas seulement être imputée à la plus grande conductivité thermique des nanoparticules en suspension. Mais, l'amélioration vient d'une combinaison de plusieurs facteurs physiques simultanés d'importance variable. À cette échelle nanométrique, le comportement thermique ne partage pas forcément les modèles des structures plus grandes, ce qui impose de faire plus de recherche pour en concevoir d'autres mieux adaptés afin d'expliquer ce que l'on observe.

Dans ce contexte, l'objectif principal de ce travail de recherche est de développer un modèle numérique simple et précis capable de modéliser la conductivité thermique des nanofluides d'Oxydes métalliques/Eau, en utilisant un plan d'expérience (Design of Experiments DOE), ensuite ce modèle est testé et analysé par la méthode ANOVA pour déterminer les effets des différents facteurs et leurs interactions. Les résultats obtenus montrent que la fraction volumique des particules présente un effet plus significatif dans l'amélioration de la conductivité thermique des nanofluides par rapport aux autres facteurs. Contrairement à l'effet de la taille des particules, l'augmentation de la fraction volumique et de la température des particules possède un effet positif sur l'amélioration de la conductivité thermique des nanofluides. Les valeurs R^2 et RMSE de 0,99 et 0,0074 respectivement, indiquent ainsi que le modèle de TCR fournit une bonne corrélation et que les valeurs prédites et expérimentales s'adaptent parfaitement. Enfin, les résultats obtenus par DOE confirment la capacité du modèle proposé à prédire la conductivité thermique des nanofluides avec une grande précision.

Le second objectif de ce travail est l'étude de l'application des réseaux de neurones artificiels (RNA) pour prédire les propriétés thermophysiques du nanofluide (Al_2O_3/Eau). La conductivité thermique TCR (k_{nf}/k_f) et la viscosité DVR (μ_{nf}/μ_f) du nanofluide sont respectivement modélisées. Les résultats de cette modélisation montrent que la meilleure

architecture trouvée pour le taux de TCR et DVR est de 15 et 20 neurones dans la couche cachée respectivement. Le modèle (k_{nf}/k_f) fournit une bonne corrélation entre les valeurs prédites et expérimentales avec des valeurs de R^2 égales à 0,998 et 0,998 pour l'apprentissage et la validation. De plus, puisque les valeurs de MSE sont de 0,000018 pour l'apprentissage et de 0,0000162 pour la validation pour (μ_{nf}/μ_f), donnant ainsi une excellente corrélation entre la réponse prédite et observée ; avec des valeurs plus élevées de $R^2 = 0,999$ et de valeurs faibles de $MSE = 0,000788$ pour l'apprentissage et $R^2 = 0,999$ et $SME = 0,000678$ pour la validation.

La comparaison avec les diverses corrélations empiriques prenant en compte les valeurs AARD de 0.0019 % pour (k_{nf}/k_f) et de 0.013 % pour (μ_{nf}/μ_f) confirme que le modèle proposé a des performances supérieures dans la prédiction du TCR et du DVR des nanofluides Alumine/Eau et peut être considéré comme un outil pratique pour la tâche considérée.

Mots clé : Nanofluides, Nanoparticule, Oxydes métalliques, Conductivité thermique, Viscosité dynamique, Plan d'expérience, RNA.

Abstract

Nanofluids have recently been considered one of the most popular working fluids in heat transfer and fluid mechanics. A precise estimation of the thermophysical properties of nanofluids is necessary for the study of their heat transfer performance. Thermal conductivity coefficient and viscosity are some of the most important thermophysical properties that directly influence the application of nanofluids.

An increase in the thermal conductivity of nanofluids cannot only be attributed to the greater thermal conductivity of the suspended nanoparticles. But, the improvement comes from a combination of several simultaneous physical factors of varying importance. At this nanometric scale, thermal behavior does not necessarily share the models of larger structures, which requires doing more research to design appropriate models to explain what we observe.

In this context, the main objective of this research work is to develop a simple and precise numerical model capable of modeling the thermal conductivity of metal oxides / water nanofluids, by using an experimental design (Design of Experiments DOE). This model is then tested and analyzed by the ANOVA method in order to determine different factors' effects of and their interactions. The obtained results show that the volume fraction of the particles has most significant effect in improving nanofluids thermal conductivity compared to the other factors. Unlike the effect of particle size, increasing the volume fraction and temperature of the particles has a positive effect on improving nanofluids thermal conductivity. The R^2 and RMSE values are of 0.99 and 0.0074 respectively; indicating that the TCR model provides a good correlation hence fitting perfectly predicted and experimental values. Consequently, the results obtained confirm the capacity of the proposed model of our study to predict nanofluids thermal conductivity with great precision.

The second objective of the present research is to study Artificial Neural Networks (ANNs) application to predict thermophysical properties of (Al_2O_3 /Water) nanofluid. The nanofluid thermal conductivity and its viscosity are thus respectively modeled. The results of this modeling show that the best architecture found for the rate of TCR (k_{nf}/k_f) and DVR (μ_{nf}/μ_f), is of 15 and 20 neurons in the hidden layer respectively. The model of (k_{nf}/k_f) provides a good correlation between predicted and experimental values with values of R^2 equal to 0.998 and 0.998 for both learning and validation. In addition, the MSE values are of

0.000018 for learning and 0.0000162 for validation. An excellent correlation is also noticed between the predicted and observed response for (μ_{nf}/μ_f) , with thus a higher values of $R^2=0.999$ and a lower values of $MSE=0.000788$ for training and $R^2=0.999$ and $SME=0.000678$ for validation.

Comparison with various empirical correlations, taking into account the AARD% values of 0.013 % for (μ_{nf}/μ_f) and of 0.0019 % for (k_{nf}/k_f) , confirms that the proposed model has greater performance in the prediction of TCR and DVR of Alumina/Water nanofluids and thus can be considered as a practical tool for the considered task.

Keywords: Nanofluids, Nanoparticle, Metal Oxides, Thermal Conductivity, Dynamic Viscosity, Experimental Design, RNA.

ملخص

مؤخرًا تعتبر الموائع النانوية الأكثر شيوعًا في مجال نقل الحرارة وميكانيكا الموائع. يعد التقدير الدقيق للخصائص الفيزيائية الحرارية للموائع النانوية ضروريًا لدراسة أداء نقل الحرارة. يعتبر معامل التوصيل الحراري واللزوجة من أهم الخصائص الفيزيائية الحرارية التي تؤثر بشكل مباشر على تطبيق السوائل النانوية.

لا يمكن ان تنسب هذه الزيادة في التوصيل الحراري للمائع النانوي إلى الموصلية الحرارية العالية للجسيمات النانوية المعلقة فقط. أما التحسين يأتي من مزيج عدة عوامل فيزيائية متزامنة ذات أهمية متفاوتة. في هذا المقياس النانوي ، لا يشترك السلوك الحراري بالضرورة في نماذج ذات الهياكل الأكبر ، الأمر الذي يتطلب إجراء المزيد من الأبحاث لتصميم نماذج أخرى أكثر ملاءمة لشرح ما نلاحظه.

في هذا السياق ، يتمثل الهدف الرئيسي لهذا العمل البحثي في تطوير نموذج رقمي بسيط ودقيق قادر على نمذجة التوصيل الحراري لأكاسيد المعادن / موائع المياه النانوية ، باستخدام تصميم تجريبي (تصميم التجارب *DOE*) ، بعد ذلك يتم اختبار هذا النموذج وتحليله بواسطة طريقة ANOVA لتحديد تأثيرات العوامل المختلفة وتفاعلاتها. أظهرت النتائج المتحصل عليها أن حجم الجسيمات له تأثير أكبر في تحسين التوصيل الحراري للموائع النانوية مقارنة بالعوامل الأخرى. و على عكس تأثير قطر الجسيمات ، فإن زيادة تركيز الحجم ودرجة حرارة الجزيئات له تأثير إيجابي على تحسين التوصيل الحراري للسوائل النانوية. قيمتا R^2 (معامل الانحدار الخطي) : 0.99 و RMSE (جذر متوسط الخطأ التربيعي) : 0.0074 على التوالي وهذا يدل على أن نموذج TCR (نسبة التوصيل الحراري) يوفر علاقة جيدة وأن القيم المتوقعة والتجريبية مناسبة تمامًا. أخيرًا ، تؤكد النتائج التي تم الحصول عليها قدرة النموذج المقترح في دراستنا على التنبؤ بالتوصيل الحراري للسوائل النانوية بدقة كبيرة.

الهدف الثاني هو دراسة تطبيق الشبكات العصبية الاصطناعية (RNA) للتنبؤ بالخصائص الفيزيائية الحرارية للسوائل النانوية (أكسيد الألومنيوم/ الماء). تم تصميم الموصلية الحرارية ولزوجة السائل النانوي على التوالي. تظهر نتائج هذه النمذجة أن أفضل بنية تم العثور عليها لمعدل TCR (نسبة التوصيل الحراري) (k_{nf}/k_f) و DVR (نسبة اللزوجة الديناميكية) (μ_{nf}/μ_f) هي 15 و 20 خلية عصبية في الطبقة المخفية على التوالي. يوفر النموذج (k_{nf}/k_f) ارتباطًا جيدًا بين القيم المتوقعة والتجريبية بقيم R^2 تساوي 0.998 لكل من التعلم والتحقق، بالإضافة إلى قيم

MSE (متوسط الخطأ التربيعي) البالغة 0.000018 للتعلم و 0.0000162 للتحقق. كما لوحظ وجود ارتباط ممتاز بين الاستجابة المتوقعة والملاحظة لـ (μ_{nf}/μ_f) وبالتالي ، فإن القيم الأعلى لـ $R^2 = 0.999$ والأقل لـ $MSE = 0.000788$ للتعلم ، كذلك القيم الأعلى لـ $R^2 = 0.999$ والأقل لـ $MSE = 0.000678$ للتحقق من الصحة.

المقارنة مع الارتباطات التجريبية المختلفة مع الأخذ في الاعتبار قيم $\%AARD$ لـ (k_{nf}/k_f) هي 0.0019 % و 0.013 % لـ (μ_{nf}/μ_f) يؤكد أن النموذج المقترح له أداء متفوق في التنبؤ بـ TCR و DVR للسوائل النانوية (الألومينا/الماء) ويمكن اعتباره أداة عملية للمهمة المدروسة.

الكلمات المفتاحية: الموائع النانوية ، الجسيمات النانوية ، أكاسيد المعادن ، التوصيل الحراري ، اللزوجة ، التصميم التجريبي ، RNA .

Table des matières

Dédicace	
Remerciements	
Résumé	
Abstract	
ملخص	
Sommaire	i
Liste des abréviations	iv
Liste des figures	vi
Liste des tableaux	vii
Introduction générale	1
Chapitre I	
<i>Généralité et revue bibliographique</i>	
I.1 Introduction	4
I.2 Les nanofluides	4
I.2.1 Définition et propriétés des nanoparticules	4
I.2.2 Les Nanoparticules et les fluides porteurs.....	6
I.2.3 Confection des nanoparticules et des nanofluides.....	8
I.2.4 État de l’art des nanofluides	9
I.2.5 Revue bibliographique	13
I.2.6 Domaines d’applications des nanofluides	21
I.3 Caractéristiques thermophysiques des nanofluides	24
I.3.1 Conductivité thermique des nanofluides	25
I.3.2 La viscosité dynamique	35
I.3.3 La masse volumique	40
I.3.4 La chaleur spécifique.....	41
I.3.5 Coefficient d’expansion thermique	42
I.4 Conclusion	42
I.5 Références	43
Chapitre II	
<i>Approche mathématique</i>	

II.1 Théorie des plans d'expériences	51
II.1.1 Introduction.....	51
II.1.2 Domaine d'application des plans d'expériences.....	51
II.1.3 Modélisation et logiciels.....	52
II.1.4 Méthodologie des plans d'expériences.....	52
II.2 Les Réseaux de Neurones Artificiels	59
II.2.1 Introduction.....	59
II.2.2 Domaines d'application des réseaux de neurones artificiels.....	60
II.2.3 Fonctionnement des réseaux de neurones.....	60
II.2.4 Le modèle neurophysiologique.....	62
II.2.5 Modélisation d'un neurone formel.....	62
II.2.6 Architecture des réseaux de neurones.....	65
II.2.7 L'apprentissage.....	68
II.2.8 Le Perceptron Multicouches (MLP).....	69
II.2.9 Conclusion.....	71
II.3 Références	72
Chapitre III	
<i>Modélisation de la conductivité thermique effective des nanofluides par l'utilisation des plans d'expériences à Plan factoriel complet</i>	
III.1 Introduction	74
III.2 Position du problème	76
III.2.1 Caractéristiques des matériaux.....	76
III.2.2 Méthodologie.....	77
III.2.3 Choix de la réponse, des facteurs et du type de plan correspondant.....	78
III.2.4 Modèle mathématique.....	78
III.3 Résultats et discussion	79
III.3.1 Test du modèle proposé.....	82
III.3.2 Validation du modèle proposé.....	86
III.4 Conclusion	90
III.5 Références	90
Chapitre IV	
<i>Application des Réseaux de Neurones Artificiels (RNA) pour prédire les propriétés thermophysiques de nanofluide (Al₂O₃/Eau)</i>	

IV.1 Introduction	96
IV.2 Réseaux de neurones artificiels	97
IV.2.1 Type de modèle RNA.....	98
IV.2.2 Procédure d'apprentissage de réseaux de neurones artificiels	99
IV.3 Méthodologie	100
IV.3.1 Données expérimentales.....	100
IV.3.2 Développement du modèle RNA.....	101
IV.3.3 Choix de l'algorithme d'apprentissage.....	102
IV.4 Résultats et discussion	104
IV.4.1 Estimation de la conductivité thermique basée sur RNA.....	104
IV.4.2 Estimation de la viscosité dynamique basée sur RNA	109
IV.5 Conclusion	114
IV.6 Références	115
Conclusion générale	120
Annexes	

Liste des abréviations

Nomenclature

c_p	Chaleur spécifique, J/kg.K
d	Diamètre moléculaire moléculaire, nm
h	Coefficient transfert thermique, W/m ² .K
K	Conductivité thermique, W.m ⁻¹ .K ⁻¹
k_B	Constante du Boltzmann, 1.381 × 10 ⁻²³ J/K
n	Facteur de forme empirique (Chapitre I)
T	Température, K

Greek Letters

β	Rapport de l'épaisseur de la couche nanométrique sur le rayon des particules
β_T	Coefficient de dilatabilité
η	La viscosité intrinsèque (Chapitre I)
λ	Conductivité thermique, W/m.K (Chapitre I)
μ	Viscosité dynamique, kg.m ⁻¹ .s ⁻¹
ρ	Masse volumique, kg/m ³
φ	Fraction volumique
ϕ	Fraction volumique (Chapitre III)
ψ	Sphéricité

Nombres sans dimension

Pr	Nombre de Prandtl
Re	Nombre de Reynolds

Indices

bf	Base fluid
eff	Effective
Exp	Données expérimentales
exp	Expérimental
f	Fluid
nf	Nanofluid
p	Particle

pré	Prédit
S	Solide
Abréviation	
μ_{nf}/μ_f	Dynamic viscosity ratio
Ag	Argent
Al	Aluminium
Al ₂ O ₃	Oxyde d'Aluminium
ANOVA	Analysis of variance
Au	l'Or
CHT	Transfert de chaleur par convection
Cu	Cuivre
CuO	Oxyde de Cuivre
DOE	Design of Experiments
DVR	Dynamic viscosity ratio
EG	L'éthylène glycol
H-C	Hamilton-Crosser
JMP	John's Macintosh Product
K_{nf}/K_f	Thermal conductivity ratio
LM	Levenberg Marquardt
MLP	Perceptron multicouches
MWCNT	Nanotubes de carbone à parois multiple
NTC	Nanotubes de carbone
RNA	Réseaux de neurones artificiels
RP	Retropropagation
SWNCH	Nanohorns de carbone à paroi unique
TC	Conductivité thermique
TiO ₂	Dioxyde de Titane
TRC	Thermal conductivity ratio

Liste des figures

Figure I.1: Illustration de la structure d'un fullerène nC60 [4].....5

Figure I.2: Illustration de la corrélation entre taille et surface spécifique [4].....5

Figure I.3: Images TEM de quelques exemples de nanoparticules : (a) Nanoparticules sphériques, (b) Nanotubes de carbone et Nanofeuilles de (c) graphène [5].6

Figure I.4: Différence de conductivité thermique entre les fluides de base A (couramment utilisés) et nanoparticules B (couramment utilisées) [9].....8

Figure I.5: Pyrolyse par LASER donnant de la nano poudre à mélanger au liquide ainsi que le dépôt direct dans le liquide par pulvérisation cathodique sous vide [6].9

Figure I.6: Procédés physique-chimique pour la préparation du nanofluide.9

Figure I.7: Nombre de publications pour les dix dernières années [9].12

Figure I.8: Nombre de publications des nanofluides NF, et de leurs conductivités thermiques TC et le transfert de chaleur par convection CHT au cours des dernières années (Web of Science) [31].12

Figure I.9: Différentes structures des nanotubes identifiées [7].19

Figure I.10: Explication schématisée de la création d'un réseau de ponts thermiques (trait rouge) créé par une dispersion de nano-fibres (trait noir) dans un liquide (Beige) qui permet la propagation de la chaleur d'une zone chaude (ovale rouge) vers une zone froid [7].....20

Figure I.11: Paramètres affectants la conductivité thermique des nanofluides [72, 73].....26

Figure I.12: Comparaison des résultats prédits du modèle de H-C avec ceux d'autres modèles pour les nanofluide (Al₂O₃/Eau) [7].32

Figure I.13: Comparaison des résultats expérimentaux de nanofluides (Al₂O₃/Eau) et ceux obtenus à partir des modèles de H-C et de Yu-Choi [7].32

Figure I.14: Comparaison entre les résultats prédits du modèle de H-C avec ceux obtenus expérimentalement pour les nanofluides (CuO/Eau) [7].33

Figure I.15: Comparaison entre les résultats du modèle de H-C avec des résultats expérimentaux pour les nanofluides (Cu/Eau) et pour deux valeurs de ψ [7].33

Figure I.16: Comparaison des résultats prédits par le modèle de H-C et des résultats obtenus par d'autres modèles pour les nanofluides (NTC/Eau) [7].34

Figure I.17: Comparaison des résultats prédits par le modèle de H-C et des résultats obtenus expérimentalement pour des nanofluides (NTC/Eau) [7].	34
Figure I.18: Paramètres affectant la viscosité des nanofluides [72].	37
Figure II.1: Domaine du facteur [5].	53
Figure II.2: Espace expérimental [5].	54
Figure II.3: Domain d'étude [5].	54
Figure II.4: Illustration de la surface de réponse [4].	55
Figure II.5: Disposition des points expérimentaux d'un plan 2^3 [6].	56
Figure II.6: La fonction désirabilité varie de 0 à 1 quand la réponse s'améliore progressivement [5].	59
Figure II.7: Structure d'un réseau de neurone biologique et le cerveau humain [12].	61
Figure II.8: Modèle d'un neurone biologique.	62
Figure II.9: Modèle d'un neurone artificiel [15].	63
Figure II.10: Fonctions d'activations : (a) du neurone « seuil » ; (b) du neurone « linéaire », et (c) du neurone « sigmoïde ».	64
Figure II.11: Schéma d'un réseau de neurones monocouche.	66
Figure II.12: Schéma d'un réseau de neurones non bouclé (Perceptron multicouches).	67
Figure II.13: Schéma de réseau de neurones bouclé.	68
Figure II.14: Principe de l'apprentissage.	69
Figure II.15: Réseau de neurones de type perceptron à une couche cachée.	70
Figure II.16: Apprentissage des réseaux de neurone par l'algorithme de rétro-propagation.	71
Figure III.1: les valeurs actuelles de TCR en fonction des valeurs prédites.	82
Figure III.2: Prédiction de TCR par rapport à $X_1(\Phi)$, $X_2(T)$, $X_3(dp)$ et $X_4(Np)$.	85
Figure III.3: Profils de prédiction aux paramètres optimaux.	86
Figure III.4: Effets de la fraction volumique des nanoparticules sur TCR du nanofluide CuO/Eau par rapport au modèle proposé pour différents diamètres : (a) 295 K et (b) 298 K.	86
Figure III.5: Effets de la fraction volumique des nanoparticules sur TCR du nanofluide de (a) Al_2O_3 /Eau et (b) TiO_2 /Eau par rapport au modèle proposé pour différents diamètres.	87
Figure III.6: Effets de la température sur TCR du nanofluide de (a) CuO-Eau and (b) Al_2O_3 -Eau, par rapport au modèle proposé.	87

Figure III.7: Comparaison des résultats des modèles expérimentaux et théoriques de TCR de nanofluide CuO/eau avec le nouveau modèle proposé, en fonction de la fraction volumique.....	88
Figure III.8: Comparaison des résultats des modèles expérimentaux et théoriques de TCR de nanofluide CuO-eau avec le nouveau modèle proposé, en fonction de la température.	89
Figure III.9: Effets de la fraction volumique des nanoparticules sur le TCR des nanofluides par rapport au modèle proposé pour différentes nanoparticules.	89
Figure IV.1: Architecture d'une structure neuronale MLP	98
Figure IV.2: Schéma bloc de l'apprentissage d'un réseau de neurones.....	100
Figure IV. 3: Structure de réseau de neurone utilisé dans cette étude	100
Figure IV.4: Algorithme de réseau neuronal utilisé dans ce travail.....	103
Figure IV.5: Comparaison statistique	105
Figure IV.6: Apprentissage de RNA utilisant 15 neurones dans une couche cachée.	106
Figure IV. 7: Valeurs estimées du taux d'amélioration de conductivité thermique. a) données d'apprentissage, b) données de validation.....	106
Figure IV. 8: Erreurs de RNA pour TCR . a) données d'apprentissage, b) données de validation.....	107
Figure IV.9: Graphe des données expérimentales du TCR en fonction des valeurs prédites par le meilleur modèle MLP. a) données d'apprentissage, b) données de validation.....	107
Figure IV.10: Évaluation comparative pour la prédiction de la TCR du nanofluide du modèle MLP développé avec des modèles classiques et expérimental mesuré par Chandrasekar et al. [41]......	109
Figure IV.11: Comparaison statistique	110
Figure IV.12: Apprentissage de RNA utilisant 20 neurones dans une couche cachée.	111
Figure IV.13: Valeurs estimées du rapport de viscosité. a) données d'apprentissage, b) données de validation.....	111
Figure IV.14: Erreurs de RNA pour DVR . a) données d'apprentissage, b) données de validation.....	112
Figure IV. 15: Graphe des données expérimentales du DVR en fonction des valeurs prédites par le meilleur modèle MLP. a) données d'apprentissage, b) données de validation	112
Figure IV. 16: Comparaison du modèle proposé (MLP) avec les modèles existants pour la prédiction de la viscosité relative des nanofluides.....	113

Liste des tableaux

Tableau I.1: Résultats donnant les valeurs maximales des conductivités thermiques obtenues pour différents nanofluides avec des nanoparticules sphériques d’oxydes métalliques et différents fluides de base.....17

Tableau I.2: Valeurs maximales de la conductivité thermique des nanofluides utilisant des nanoparticules métalliques obtenues par différents auteurs.....18

Tableau I.3: Valeurs mesurées de la conductivité thermique des nanofluides avec des nanotubes de carbone pour différents fluides de base et pour différentes valeurs de la fraction volumique.21

Table I.4: Valeurs calculées de (k_{nf}/k_f) à partir du modèle H-C en fonction de ϕ % pour deux nanofluides (NTC/Eau) et (NTC/EG) [7].....35

Table I.5: Valeurs de k_{nf}/k_f calculé à partir du modèle de H-C en fonction de ϕ , pour différents nanofluides et avec l’eau comme fluide porteur35

Table I.6: Rapport de masses volumiques des différents nanofluides en fonction de la fraction volumique [7]41

Tableau II.1: Matrice d’un plan d’expériences 23 et résultats expérimentaux.....57

Tableau II.2: Analogie entre le neurone biologique et le neurone formel [15].....61

Tableau II.3: Différentes fonctions d'activations utilisées dans les RNA.65

Tableau III.1: Caractéristiques des nanofluides à base d'eau adoptées dans ce travail.77

Tableau III.2: Propriétés thermophysiques de l'eau et des nanoparticules sélectionnées.77

Tableau III.3: Les facteurs sélectionnés à différents niveaux du plan factoriel.80

Tableau III.4: Matrice d’expérience.....81

Tableau III.5: Valeurs des constantes.....82

Tableau III.6: Prédiction de modèle et les erreurs standards.84

Tableau III.7: Analyse de variance ANOVA pour TCR.....85

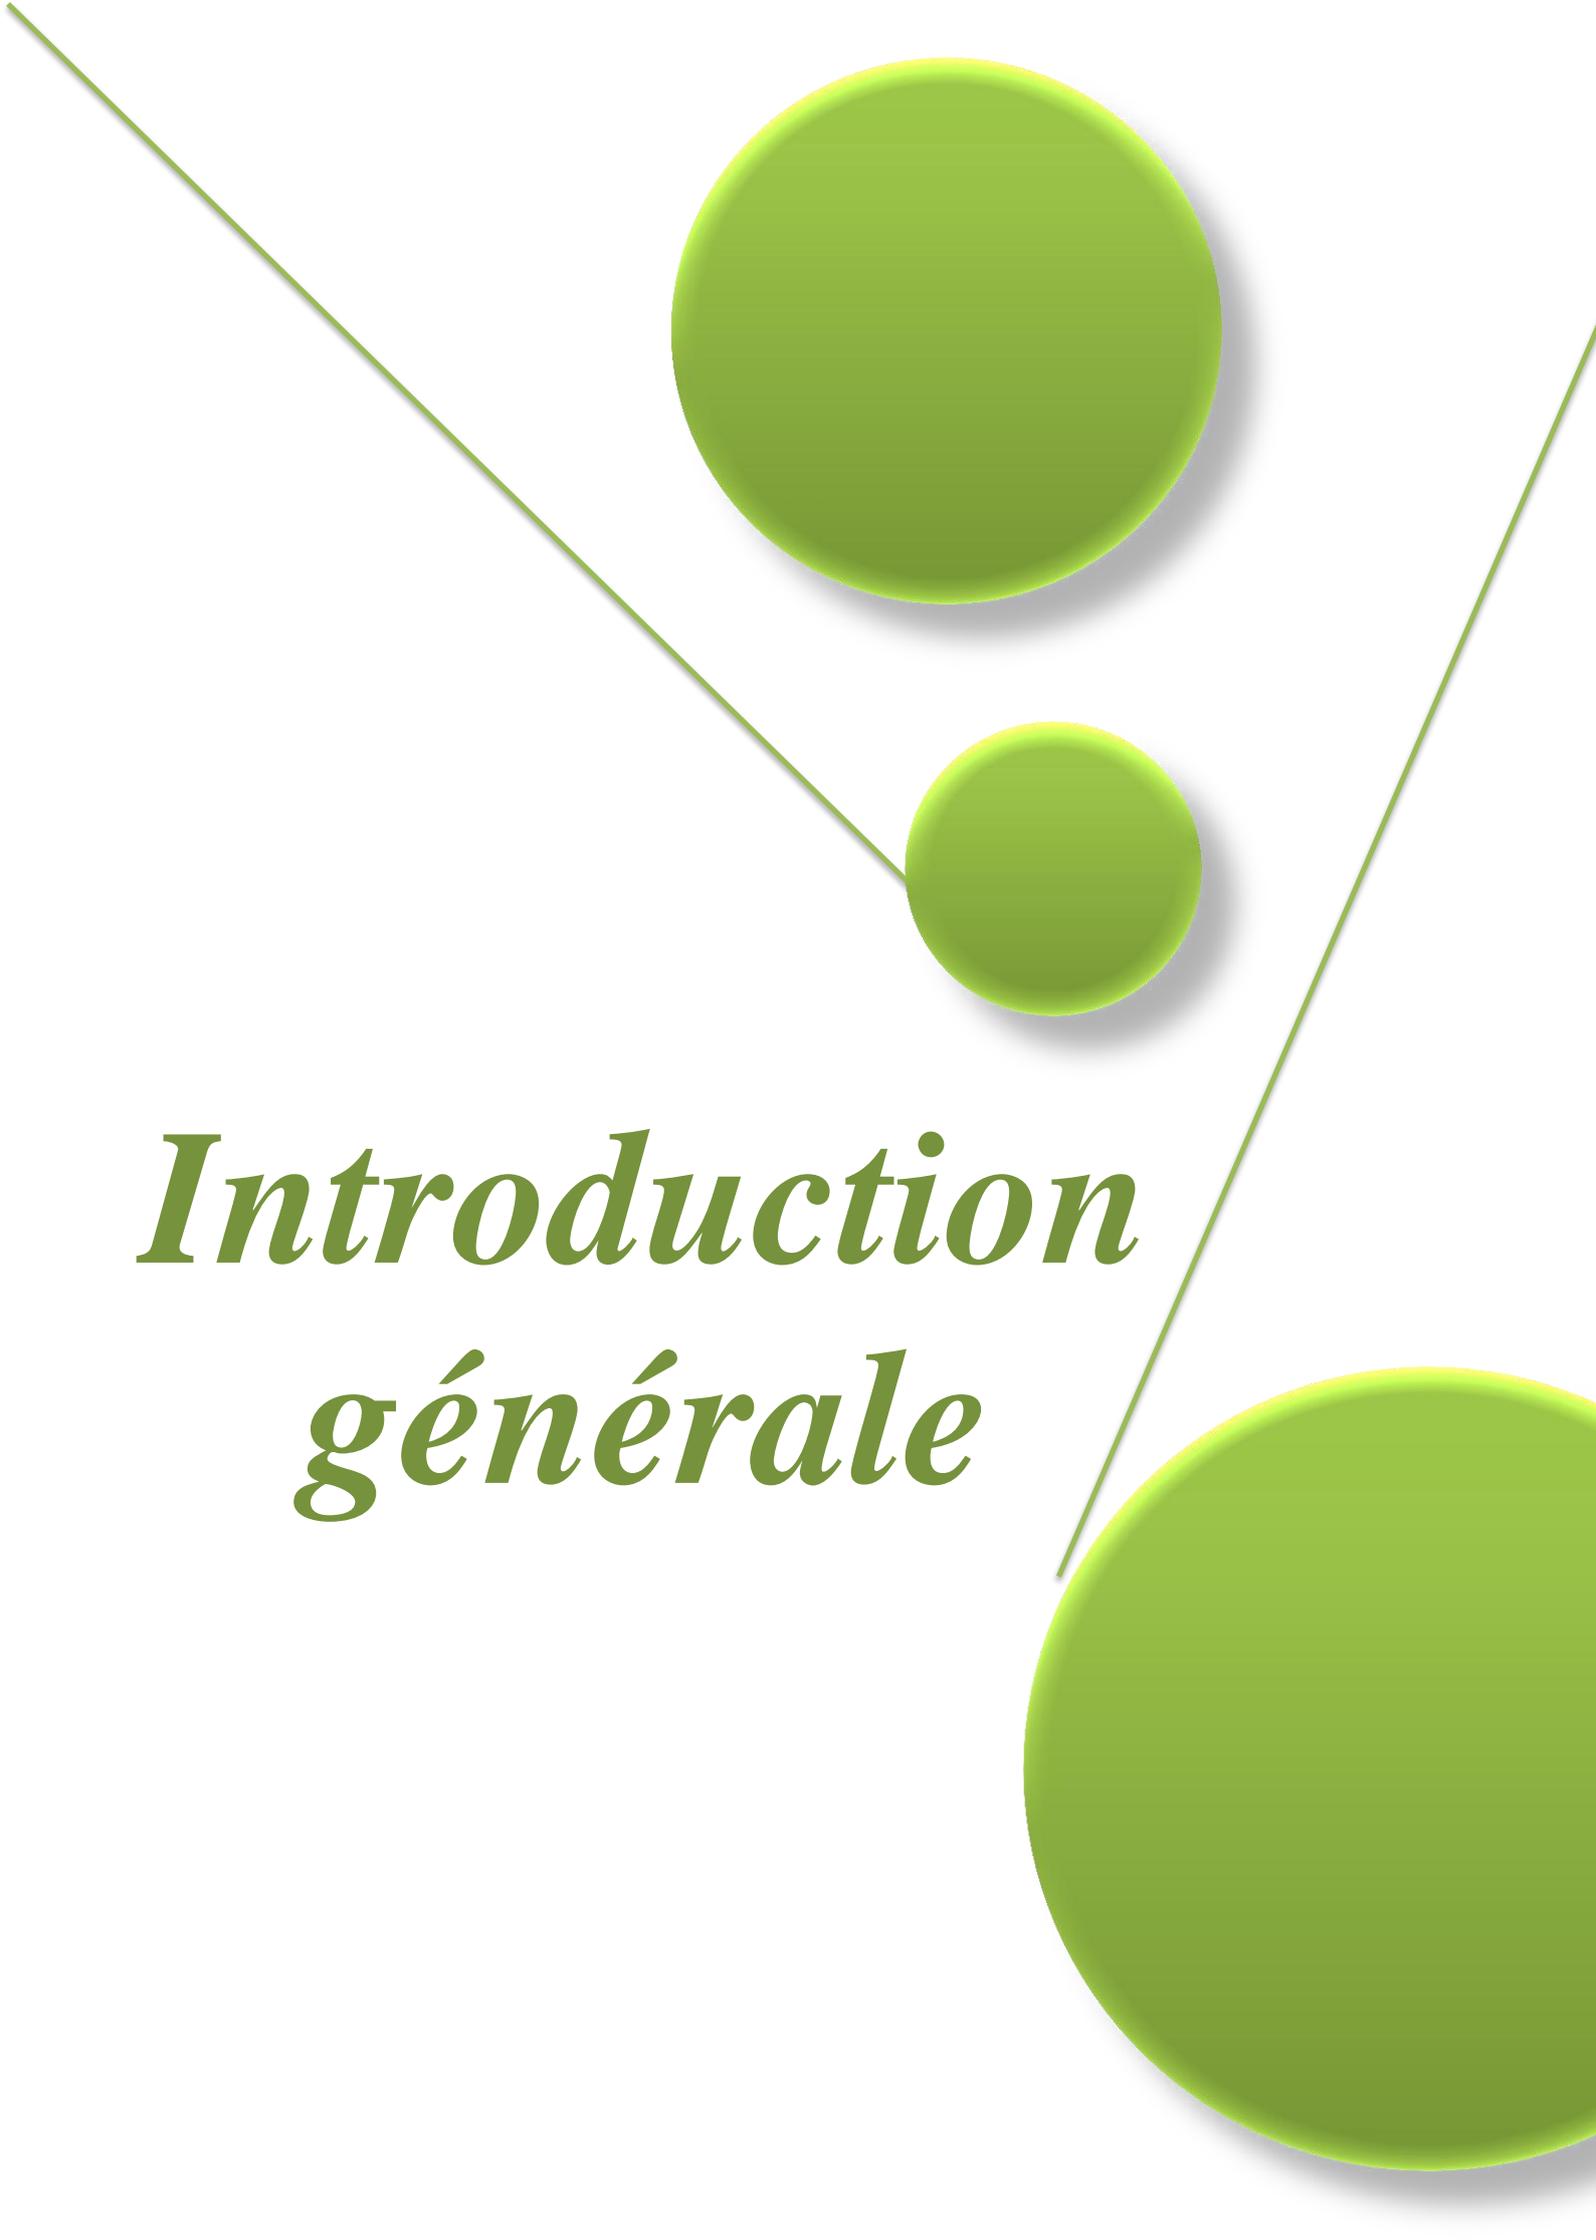
Tableau IV.1: Gammes de paramètres pour le nanofluide Al_2O_3 / Eau101

Tableau IV.2: Indicateur d'évaluation des modèles102

Tableau IV.3: Évaluation des performances du réseau de neurones MLP pour les échantillons d'apprentissage et de test pour TCR.104

Tableau IV.4: Comparaisons de la précision prédictive de différentes corrélations intelligentes et empiriques de TCR expérimental mesuré par Chandrasekar et al. [41]108

Tableau IV.5: Évaluation des performances du réseau de neurones MLP pour les échantillons d'entraînement et de test pour DVR.110

The background features a white surface with three large, vibrant green circles of varying sizes. A thin green line starts from the top left, passes through the center of the largest circle, and ends near the center of the smallest circle. Another thin green line starts from the top right and extends towards the bottom right, passing near the bottom edge of the largest circle. The text is centered in the lower half of the page.

*Introduction
générale*

Introduction générale

Dans notre vie quotidienne, le transfert de chaleur et de l'énergie constitue la base de nombreux processus industriels. L'épuisement progressif des énergies fossiles conduit à améliorer et optimiser les rendements de ces échanges par de nouveaux procédés. Les « nanofluides » peuvent s'inscrire dans ce cadre pour être l'outil de transfert thermique et énergétique de nos jours et dans l'avenir. Ils apparaissent comme un sujet de recherche mondial en raison de leur potentiel, et ils peuvent être utilisés dans les échangeurs de chaleur, les systèmes énergétiques, les capteurs solaires, les appareils électroniques, en substitution à des liquides caloporteurs traditionnels.

Une estimation précise des propriétés thermophysiques des nanofluides est nécessaire pour l'étude de leurs performances de transfert de chaleur. Le coefficient de conductivité thermique et la viscosité sont quelques-unes des propriétés thermophysiques les plus importantes qui influencent directement l'application des nanofluides.

L'idée est d'améliorer les propriétés thermiques des fluides caloporteurs en y insérant une phase solide de conductivité thermique très élevée, ainsi les nanofluides présentent une conductivité thermique significativement plus élevée que les fluides de base qui augmente avec l'augmentation de la concentration de nanoparticules. Dans leur développement et leur exploitation, il convient de trouver un compromis entre de meilleures propriétés thermiques tout en maîtrisant leur viscosité (qui ne doit pas être trop importante) et leur stabilité qui doit être assurée, sans quoi les propriétés peuvent être modifiées. Différents modèles ont été élaborés en vue d'expliquer cette remarquable améliorations de transfert de chaleur, mais la confrontation entre ces modèles pour évaluera la conductivité thermique effective des nanofluides montre que ces derniers n'approximent pas de façon satisfaisante les expériences réalisées sur les nanofluides avec différentes variétés de nanoparticules et de fluides porteurs tels que : eau, éthylène glycol,...

Plusieurs paramètres peuvent jouer un rôle dans l'efficacité des nanofluides comme la concentration et la nature des nanoparticules, leur densité, leur type, leur taille, leur aspect, la température, le fluide de base, la présence d'un surfactant, etc.

Parmi les familles de nanoparticules, les nanomatériaux d'oxydes métalliques (Al_2O_3 , CuO , TiO_2 ,...) sont d'un intérêt majeur en raison de leurs excellentes propriétés thermiques

intrinsèques et qui permettent d'obtenir des nanofluides plus performants que ceux préparés avec des nanoparticules métallique par exemple. C'est pourquoi notre travail de recherche se focalise sur les nanofluides d'oxydes métalliques.

L'objectif de ce travail est de préciser les notions qui permettent d'évaluer et d'améliorer l'aptitude du modèle postulé à représenter les résultats expérimentaux. En un mot ces notions nous aideront à trouver le modèle qui représente le mieux possible les données expérimentales et qui devrait nous permettre de faire des prévisions de qualité.

Il est nécessaire d'utiliser une approche méthodologique qui permet non seulement de réduire le coût de l'expérimentation, mais aussi d'établir une organisation optimale des expériences et séquences méthodologiques seront décrites dans ce mémoire.

À cet égard, deux approches mathématique basées sur l'analyse des données expérimentales ont été développées afin de prédire les propriétés thermophysiques des nanofluides, elles peuvent être classées en deux grandes catégories: les méthodes des plan d'expériences, tels que le plan factoriel complet et les méthodes d'intelligences artificielles, telle que les Réseaux de Neuronaux Artificiels (RNA)

Les méthodes des plan d'expériences sont très simples, permettent une bonne interprétation physique avec une minimisation du nombre nécessaire d'expériences qui permet un gain en temps et en coût financier, mais peu précises et modélisent difficilement le couplage. En revanche, la méthode des Réseaux de Neuronaux Artificiels est très précise, très souple, peut traiter un élément seul ou plusieurs éléments en réseau ou empilés, les formes arbitraires et le couplage. Cependant, elle est plus complexe, permet moins l'interprétation physique et nécessite un temps de calcul et un espace mémoire considérable. En outre, RNA a été largement utilisée pour prédire les systèmes non linéaires en raison des avantages notables de haute précision, de faible coût et de temps, par contre, la méthode de plan factoriel complète donne la meilleure estimation linéaire.

Dans ce contexte, quatre chapitres ont été présentés dans cette thèse. Le premier chapitre représente les définitions et les connaissances fondamentales sur les nanofluides y compris les différents paramètres thermophysiques qui peuvent influencer sur le comportement d'un nanofluide.

Le deuxième chapitre est composé de deux parties. La première se focalise sur l'aspect conceptuel et terminologique pour introduire les notions de base sur les plans d'expériences, cela comprend les principales techniques mathématiques utilisées pour exprimer les variations des réponses en fonction des valeurs des facteurs. Les notions fondamentales des réseaux de neurones RNA et leurs propriétés font l'objet de seconde partie de ce chapitre.

Le troisième chapitre présente la modélisation de la conductivité thermique effective des nanofluides d'oxydes métalliques. Ceci pour le développement d'une nouvelle corrélation et ceci incluant les paramètres les plus influents sur la conductivité thermique des nanofluides tel que : la concentration, la température et le diamètre de nanoparticules. Cette corrélation est générée par la méthode de plan factoriel complet. La discussion des résultats obtenue, l'évaluation de la corrélation générée qui est effectuée par la comparaison avec d'autres corrélations appliquées au même régime, ainsi que la détermination des erreurs absolues et réelles, ont été présentés dans ce chapitre.

Le quatrième chapitre s'intéresse à l'application des réseaux de neurones artificiels (RNA) pour prédire les propriétés thermophysiques de nanofluide (Al_2O_3 /Eau). Les résultats et les discussions de cette modélisation ont été exposés.

Cette thèse est terminée par une conclusion générale qui résume le travail de recherche entamé ainsi que les principaux résultats obtenus et propose d'éventuelles perspectives pour des recherches futures.

A decorative graphic featuring three green circles of varying sizes and two thin green lines. One line starts from the top left and ends at the bottom of a medium-sized circle. Another line starts from the top right and ends at the bottom of a large circle. The circles have a slight gradient and a soft shadow.

Chapitre I

I.1 Introduction

Durant ces dernières années, la consommation d'énergie a considérablement augmenté, ce qui a exhorté beaucoup de chercheurs à développer de nouvelles stratégies économiques afin de surmonter la menace d'une pénurie d'énergie. Ainsi, plusieurs systèmes énergétiques produisant un flux de chaleur très élevé ont été développés dans le domaine industriel, là où les fluides de refroidissement conventionnels ne sont pas efficaces (comme l'eau, l'éthylène glycol et l'huile). L'une des idées proposées et qui peut améliorer les propriétés thermo-physiques des fluides, est l'introduction des particules solides de très bonnes caractéristiques thermiques et de taille nanométrique au sein du fluide de base. Cette nouvelle génération de fluides porte le nom de Nanofluides (mélange colloïdal de nanoparticules de moins de 100 nm), ce terme a été proposé par Choi et Eastman [1] en 1995 et reste couramment utilisé pour caractériser ce type de suspension colloïdale. Les nanofluides ont des performances thermiques supérieures qui ne sont pas disponibles dans les fluides de transfert de chaleur traditionnels. Ainsi, l'objectif des nanofluides est d'obtenir des caractéristiques thermo-physiques les plus élevées aux plus basses concentrations possibles de nanoparticules (de préférence <1% en volume) et ceci par dispersion uniforme et une suspension stable de nanoparticules (de préférence de diamètre <10 nm) dans les fluides hôtes [2].

Ce chapitre se compose de deux parties principales.

La première, présente une synthèse bibliographique permettant une meilleure appréhension des nanofluides, de leur production, leurs domaines d'applications et leurs propriétés physiques et thermiques. Par conséquent, elle est consacrée à la présentation d'une revue bibliographique des principaux travaux publiés dans le domaine de transfert thermique des nanofluides et de leurs propriétés thermo-physiques en général. Les types de nanoparticules présentés sont classés en trois groupes : nanoparticules métalliques, nanoparticules d'oxyde métalliques et nanoparticules non métalliques.

La seconde partie est axée sur l'analyse de l'état des connaissances des propriétés thermo-physiques et du comportement thermique de ces nanofluides dans les systèmes thermiques. Une description de différents modèles utilisés pour l'estimation de ces propriétés thermo-physiques (tel que la conductivité thermique, la viscosité dynamique, la masse volumique, etc.) est aussi présentée.

I.2 Les nanofluides

I.2.1 Définition et propriétés des nanoparticules

Les nanofluides sont des dispersions de particules de taille nanométrique appelées nanoparticules, dans un fluide de base afin d'en améliorer certaines de ces propriétés. Ce

type de solution suscite un grand intérêt depuis la découverte de leurs propriétés thermiques particulières [3].

Le terme « nanoparticule » est utilisé lorsque la particule a au moins une de ses dimensions inférieures à 100 nm. Le rayon typique d'un atome étant de l'ordre de 0,1 nm, une nanoparticule peut être constituée de quelques dizaines à plusieurs centaines d'atomes. Par exemple, les nanoparticules les plus célèbres, les fullerènes, sont constituées de seulement 60 ou 70 atomes de carbone (Figure I.1). Leur très petite taille donne aux nanoparticules des surfaces spécifiques très importantes [4].



Figure I.1: Illustration de la structure d'un fullerène nC_{60} [4].

La surface spécifique développée par les nanoparticules est 1000 fois plus importante que celle d'une microparticule (Figure I.2). De même, le nombre d'atomes de surface augmente avec la diminution de la taille des nanoparticules et la réactivité, étant souvent liée à des propriétés de surface, cela explique l'intérêt développé pour les nanoparticules.

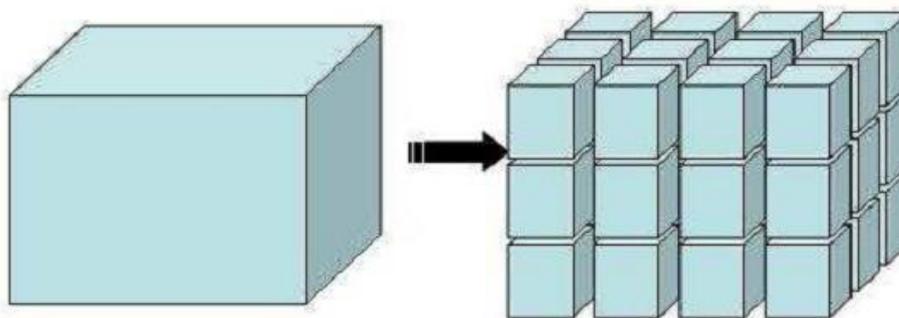


Figure I.2: Illustration de la corrélation entre taille et surface spécifique [4].

La définition par l'échelle ne suffit cependant pas à décrire tous les aspects des nanoparticules. En effet, leur réactivité est également fortement liée à leur composition qui peut être très variée. On distingue par exemple les nanoparticules organiques (constituées majoritairement de

polymères), des métalliques (ex : nanoparticules d'or ou d'argent), d'oxydes métalliques (ex : Fe_2O_3 , TiO_2) ou encore des composites (ex : quantum dots CdSe-ZnS) [4].

Les nanoparticules, jonction entre l'échelle atomique et le matériau, ont des particularités structurales très spécifiques. En effet, contrairement aux matériaux classiques, les nanoparticules voient leurs propriétés changer en fonction de leur taille. Elles sont soumises à la fois aux phénomènes de la physique classique et à ceux de la physique quantique lorsqu'elles sont de très petites tailles. Les principales propriétés des nanoparticules sont : optiques, électriques, catalytiques, thermiques, magnétiques, mécaniques ou encore biologiques [4].

I.2.2 Les Nanoparticules et les fluides porteurs

Une nanoparticule est un assemblage de quelques centaines à quelques milliers d'atomes, conduisant à un objet dont au moins l'une des dimensions est de taille nanométrique (1 à 100 nm). Les nanoparticules se situent à la frontière entre l'échelle microscopique et l'échelle atomique ou moléculaire. Elles ont un intérêt à la fois fondamental qu'appliqué et sont très étudiées de nos jours.

D'une manière générale, les nanoparticules peuvent être classées selon leur forme en trois grandes catégories (Figure I.3) [5]. Elles ont généralement la forme sphérique et cylindrique, ou en forme de tube comme les nanotubes de carbone (NTC) [6].

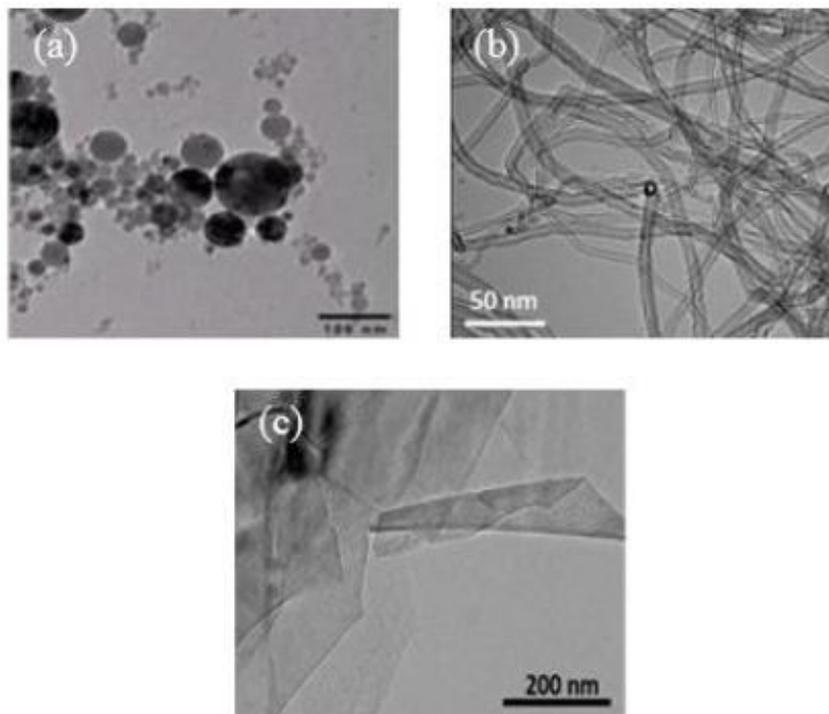


Figure I.3: Images TEM de quelques exemples de nanoparticules : (a) Nanoparticules sphériques, (b) Nanotubes de carbone et Nanofeuilles de (c) graphène [5].

Les nanoparticules les plus utilisées sont classées dans trois grandes familles, à savoir :

- Les nanoparticules d'oxydes métalliques :
 1. L'oxyde d'aluminium (Al_2O_3).
 2. L'oxyde de cuivre (CuO).
 3. L'oxyde de silicium (SiO_2).
 4. L'oxyde de Titantium (TiO_2).
- Les nanoparticules métalliques :
 1. L'aluminium (Al).
 2. Le cuivre (Cu).
 3. L'or (Au).
 4. L'argent (Ag).
- Les nanoparticules non métalliques :
 1. Les nanotubes de carbone (CNT).
 2. Le diamant (C).

Les liquides de base les plus utilisés sont :

1. L'eau.
2. L'éthylène glycol (EG).
3. Les huiles.
4. Les fluides frigorigènes (R12, R22, etc.) [6,7].

Par ailleurs, l'agitation Brownienne, liée à la taille nanométrique des particules, minimise les problèmes de sédimentation rencontrés avec des particules de plus grande dimension.

Les suspensions de nanoparticules dans un fluide (nanofluides), ont des caractéristiques thermiques intéressantes comparées aux fluides de base traditionnels [8], ainsi que des qualités indéniables d'amélioration du transfert thermique. La conductivité thermique des nanofluides peut être significativement plus élevée que celle des liquides purs (Figure I.4). Toutefois, la quantification de la conductivité thermique des nanofluides et son évaluation nécessitent le recours à une instrumentation originale. De plus, Les mesures disponibles de la conductivité thermique de différents nanofluides ne sont pas concordantes [7].

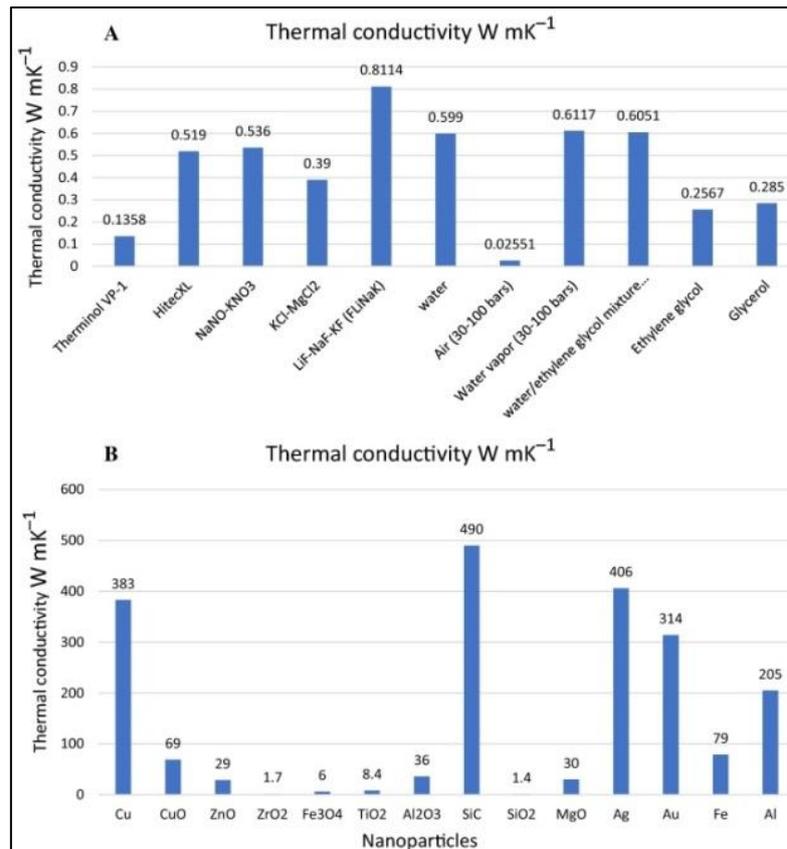


Figure I.4: Différence de conductivité thermique entre les fluides de base A (couramment utilisés) et nanoparticules B (couramment utilisées) [9].

I.2.3 Confection des nanoparticules et des nanofluides

Les expériences effectuées sur les fluides caloporteurs avec des particules de taille micrométrique (10^{-6} m) ont montré que certains problèmes pouvaient être engendrés par l'utilisation de ces dernières ; tel que le problème de sédimentation des particules, l'augmentation de perte de charges etc. Tandis que pour des particules de l'ordre du nanomètre (10^{-9} m), ces problèmes sont pratiquement insignifiants [1].

Tout en supposant que la suspension est stable et durable, l'agglomération de particules est négligeable et aucun changement chimique du fluide ; la préparation des nanofluides peut se faire par l'une des méthodes suivantes :

1. La méthode à une seule étape : basée sur la vaporisation d'un matériau solide sous vide (Figure I.5), puis condensation directe de sa vapeur dans le liquide.
2. La méthode à deux étapes : elle consiste d'abord à la fabrication d'une nanopoudre sèche, puis le mélange et la dispersion de cette dernière dans le liquide.

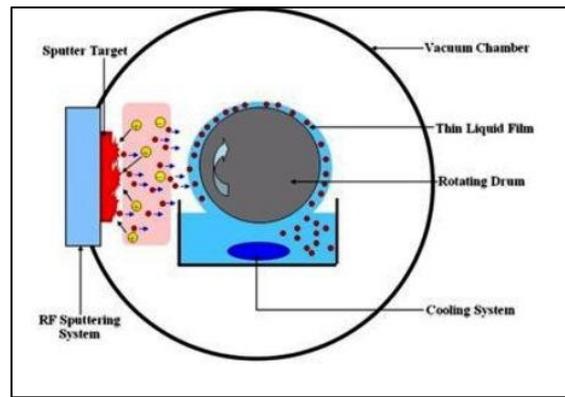


Figure I.5: Pyrolyse par LASER donnant de la nano poudre à mélanger au liquide ainsi que le dépôt direct dans le liquide par pulvérisation cathodique sous vide [6].

Les procédés de fabrication des nanoparticules sont de nature physique ou chimique [10, 11]. Ils font l'objet de beaucoup de recherches pour améliorer le coût de production qui reste toutefois élevé, vu les difficultés de mise en œuvre pour obtenir des particules de taille voulue. Chaque méthode a ses inconvénients et certaines sont inaptes à produire de grandes quantités de nanoparticules pour une production de masse vu les contraintes inhérentes au procédé. Les principaux moyens peuvent être : la mécano-synthèse (broyage à haute énergie), la précipitation chimique (réduction de sels métalliques par exemple), le **CVD ou PVD, PECVD**, la condensation des vapeurs par détente brutale dans des tuyères supersoniques, la pulvérisation cathodique à radiofréquence, la sublimation par ablation LASER, la pyrolyse LASER, la désintégration d'électrodes submergées par passage d'étincelles, etc. (Figure I.6) [3].

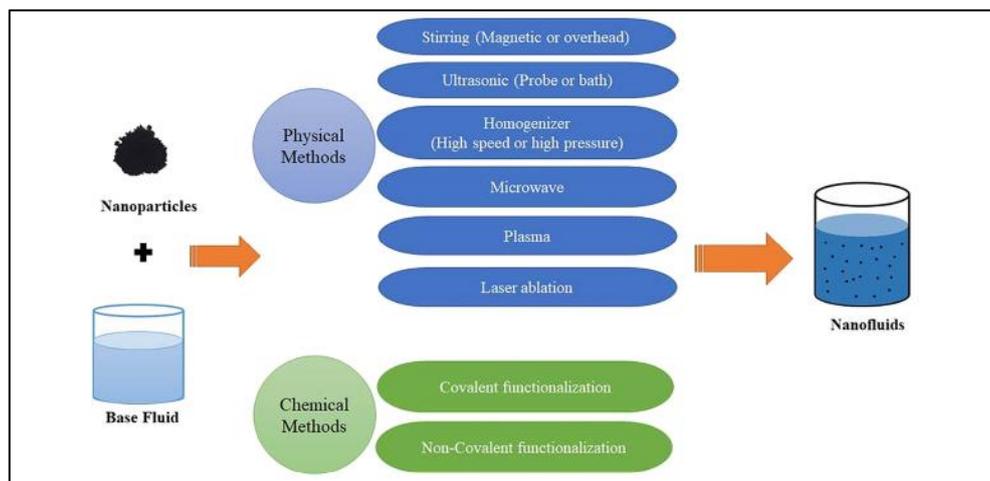


Figure I.6: Procédés physique-chimique pour la préparation du nanofluide.

I.2.4 État de l'art des nanofluides

Compte tenu de l'importance accordée aux nanofluides, plusieurs études effectuées sur leurs propriétés physiques, tels que le coefficient de transfert thermique (la conductivité

thermique), la chaleur spécifique et la viscosité dynamique, ont prouvé que les nanofluides sont très différents par rapport aux fluides de base en présentant de meilleures caractéristiques thermo-physiques. Au fait, l'ajout de micros particules solides au sein des fluides de base augmente la conductivité thermique, puisque la conductivité thermique des solides est en général plus élevée que celle des fluides [6].

Plusieurs travaux ont révélé que la conductivité thermique des fluides contenant des nanoparticules peut augmenter de plus de 20% pour le mélange Eau- Al_2O_3 (1-5 % en volume) [1]. Même en très faible concentration (1% en volume), ils permettent d'augmenter la conductivité thermique de 150% dans le cas de nanotubes de carbone [12], de 40% pour des nanoparticules d'oxyde de cuivre [13] et plus de 20% pour des Oxydes d'Aluminium [12-17].

Nous présentons dans ce qui suit les études théoriques et expérimentales portant sur les nanofluides depuis leur découverte jusqu'à nos jours.

De nombreuses recherches ont été menées depuis 2001 sur cette nouvelle classe de nanofluides afin de permettre une meilleure compréhension des mécanismes mis en jeu, et mettre ainsi au point des fluides caloporteurs plus performants. La forte conductivité thermique des nanofluides les désigne, en effet, comme des candidats potentiels pour le remplacement des fluides porteurs utilisés dans les échangeurs thermiques en vue d'améliorer leurs performances [14].

Certaines limitations susceptibles de réduire les performances des nanofluides utilisées à la place des fluides caloporteurs purs, ont été aussi étudiées. L'utilisation des nanofluides comme fluide caloporteur dans les échangeurs a montré que l'addition de nanoparticules dans un liquide augmente sa viscosité et de ce fait les pertes de charge [15]. De plus, le manque de stabilité dans le temps de certains nanofluides peut entraîner l'agglomération des nanoparticules et une modification de leur propriété de conduction thermique. Néanmoins, en l'état actuel des recherches, ces deux effets restent moins importants lors de l'utilisation de nanofluides que dans le cas de suspension de microparticules classiques [16].

En dehors des applications industrielles possibles, l'étude des nanofluides présente un intérêt scientifique pour la compréhension des phénomènes mis en jeu aux échelles nanométriques. Cependant, les propriétés thermiques des nanofluides ne concordent pas avec les prévisions fournies par les théories classiques décrivant les suspensions de particules solides dans un liquide. Malgré le nombre élevé d'études publiées sur le sujet ces dernières années, aucune théorie ne parvient à décrire convenablement les résultats expérimentaux obtenus sur les nanofluides [17]. Il est à noter aussi, que les résultats expérimentaux obtenus varient énormément d'une publication à une autre, ce qui ne facilite pas la comparaison entre ces derniers et les théories proposées.

Donc, des recherches complémentaires des propriétés thermiques des nanofluides sont nécessaires pour valider ou infirmer les différentes théories proposées [7].

Maiga *et al.* [18] ont présenté une formulation numérique pour l'étude de transfert thermique par convection forcée des nanofluides (Eau/ Al_2O_3) à l'intérieur d'un tube chauffé, et ce en proposant un modèle monophasique. Les résultats d'utilisation de ce modèle ont montré que le transfert de chaleur augmente avec l'augmentation des fractions volumiques.

Namburu *et al.* [19] ont aussi présenté un modèle monophasique dans le but d'étudier les caractéristiques de transfert de chaleur d'un nanofluide dans un tube circulaire où l'écoulement est en régime turbulent. Leurs résultats ont montré qu'il y'a une augmentation de viscosité et du nombre de Nusselt pour de petits diamètres.

D'autres chercheurs ont proposé des modèles différents et c'est à cet effet que Behzadmehr *et al.* [20] et Mirmasoumi *et al.* [21] ont utilisé le modèle diphasique d'un nanofluide dans un tube en régime de convection forcée. La comparaison des résultats calculés avec les valeurs expérimentales montre que le modèle diphasique est plus précis que le monophasé.

Au cours de la dernière décennie, l'accent des recherches sur les nanofluides est plus évident comme le montre la figure I.7, qui illustre le nombre de publications portant sur les nanofluides depuis 2010. Ces études portent notamment sur leur préparation, leur caractérisation, la mesure de leurs propriétés physiques et leur utilisation dans diverses applications. Ces données présentées en histogrammes ont été obtenues en faisant une recherche du mot « nanofluides » dans la base de données Scopus par rapport aux titres, aux résumés et aux mots clés pour la période présentée. Les résultats de cette recherche montrent qu'environ 3165 articles ont été publiés en 2019 seulement, et cette tendance devrait surement augmenter au cours des prochaines années.

Ces articles comprennent des applications sur les capteurs solaires [22, 23], les échangeurs de chaleur [24, 25], les caloducs [26], le refroidissement des radiateurs [27] et le refroidissement électronique [28] ; en plus d'une parade des travaux concernant divers propriétés thermophysiques des nanofluides [29, 30].

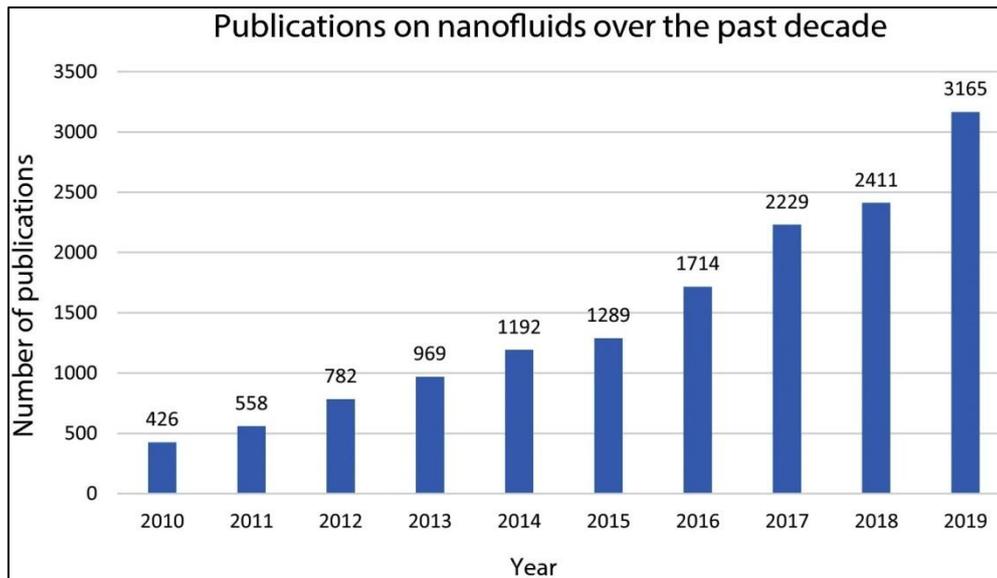


Figure I.7: Nombre de publications pour les dix dernières années [9].

La figure I.8 ci-dessous présente le nombre de publications dans le domaine des nanofluides des dernières années ainsi que les différents domaines d'utilisation.

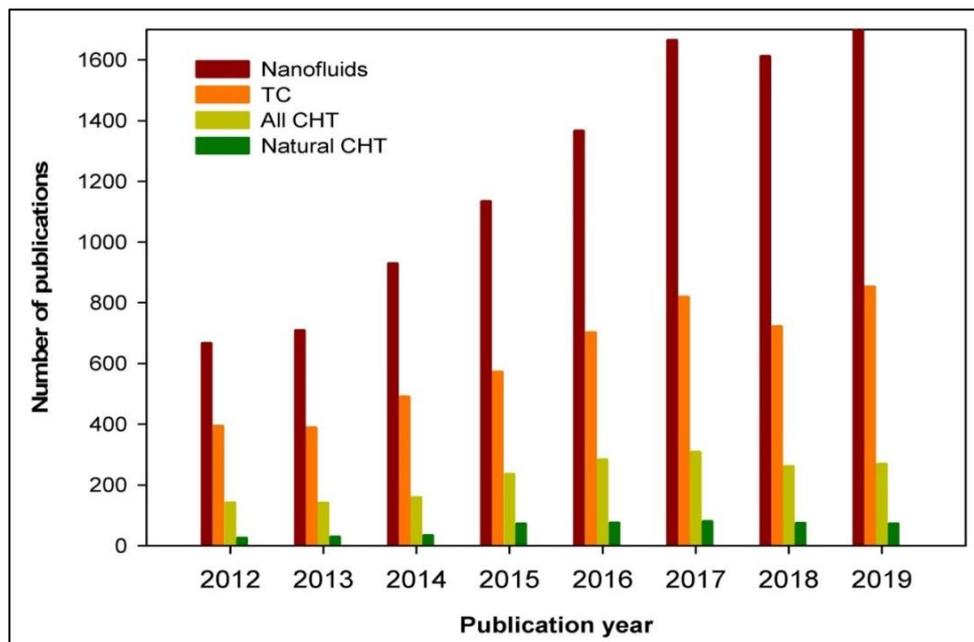


Figure I.8: Nombre de publications des nanofluides NF, et de leurs conductivités thermiques TC et le transfert de chaleur par convection CHT au cours des dernières années (Web of Science) [31].

Cette figure illustre le bilan mondial des publications concernant les nanofluides NF, y compris leur conductivité thermique (TC), la convection naturelle et le transfert de chaleur par convection (CHT), ainsi que les domaines d'application des NF (obtenues à partir de la plateforme Web of Science, Clarivate, de 2012 à 2019). Ces publications comprennent tous les types d'articles (études expérimentales, théoriques et numériques). Comme le montre cette figure, la recherche sur

la NF a continué de croître, à l'exception de la légère déclinaison de l'année 2018 (pour la première fois). On constate que les travaux sur la CT (propriété thermo-physique principale de la NF), sont les plus fréquemment publiés. En revanche, les publications sur le CHT sont restées très en retard par rapport à celles des TC et NF, avec des hauts et des bas pour la période considérée. On constate aussi que la convection naturelle, (qui ne nécessite pas de coût supplémentaire d'énergie de pompage et qui est également utilisée comme mode de refroidissement clé), n'a pas fait l'objet d'une attention considérable de la part des chercheurs. En outre, le nombre des études de convection naturelle de NF sont significativement moins que celles des TC et NF, en plus elles sont légèrement inférieures à celles de CHT (convection forcée). Ainsi, il existe un besoin évident de travaux plus accomplis sur la thermoconvection de NF, et ceci dans diverses conditions thermiques, de concentration et dans différentes géométries [31].

I.2.5 Revue bibliographique

Nous présentons dans cette partie des études expérimentales et numériques disponibles dans la littérature, sur les propriétés principales des nanofluides et leur impact sur le transfert de chaleur tel que la conductivité thermique, la chaleur spécifique et la viscosité dynamique. Diverses corrélations ont été proposées et comparées avec les expressions classiques.

Les premiers travaux traitant le transfert de chaleur en présence des nanoparticules ont pratiquement commencé en 1995 avec l'étude de Choi [1], qui ont permis plus tard de déterminer les propriétés thermophysiques des nanofluides. Par la suite, plusieurs études expérimentales et numériques ont été menées par différents chercheurs pour comprendre et analyser le comportement thermo-hydrauliques des nanofluides. Ces études peuvent être classées en trois catégories selon le type de matière des nanoparticules :

- Les nanoparticules d'oxyde métallique.
- Les nanoparticules métalliques.
- Les nanoparticules non métalliques.

1.2.5.1 Les nanoparticules d'oxyde métallique

L'idée d'insérer, au sein du fluide, des particules de taille nanométriques pour espérer augmenter la conductivité thermique effective du mélange est apparue depuis Maxwell en 1881 [32]. Plusieurs types de matériaux peuvent être utilisés pour l'obtention de nanoparticules sphériques. Ces nanoparticules peuvent être fabriquées à l'aide de métaux solides ou d'oxyde métallique. Les oxydes métalliques sont faciles à produire, ils sont chimiquement stables et faciles à disperser dans l'eau.

✓ Les nanoparticules d'oxyde d'Aluminium

L'essentiel des travaux sur ce type de nanofluides a porté sur la mesure de la conductivité thermique en fonction des différents paramètres caractérisant les nanoparticules (taille, fraction massique et température de l'ensemble).

Le premier travail publié sur l'amélioration de la conductivité thermique utilisant l'oxyde d'aluminium a été mené par Masuda et *al.* en 1993 [33]. En dispersant des nanoparticules (Al_2O_3) dans l'eau dont la taille est de 13nm de diamètre. Ils ont obtenu une amélioration de la conductivité thermique de 30% pour une fraction volumique $\phi = 4.3\%$. Ce résultat a été suivi par une autre étude publiée par Eastman et *al.* [8] qui ont trouvé une amélioration de 30% de la conductivité thermique de nanoparticules (Al_2O_3) de taille 33nm en suspension dans l'eau pour une fraction volumique de 5%.

Les travaux de Wang et *al.* [34] ont porté sur l'étude numérique de la convection naturelle dans une cavité bidimensionnelle pour différents nombres de Grashof et pour différentes concentrations en volume. Ils ont obtenu une amélioration de la conductivité thermique de 40% pour (Ethylène Glycol / Al_2O_3) de fraction volumique 8% et une augmentation de 14% pour (Eau/ Al_2O_3) avec une fraction volumique de 4.5%.

Lee et *al.* [35] ont mesuré la conductivité thermique des nanofluides d'oxyde de cuivre (CuO) et d'oxyde d'aluminium (Al_2O_3) dans deux liquides de base : l'eau et l'éthylène glycol obtenant ainsi une amélioration de 10% de la conductivité thermique pour le nanofluide (Eau/ Al_2O_3) de fraction volumique 4.3% et une amélioration de 20% pour (Ethylène Glycol/ Al_2O_3) d'une fraction $\phi = 5\%$. Ces derniers résultats diffèrent considérablement de ceux obtenus par les précédents auteurs malgré leur utilisation de nanoparticules de même taille.

En 2003 Das et *al.* [36] furent les premiers à investiguer l'influence de la température sur l'accroissement de la conductivité thermique des nanofluides. Ils ont relevé une augmentation de la conductivité thermique lorsque la température varie de 21°C à 51°C pour les deux nanofluides (Eau/ Al_2O_3) et (Eau/CuO) avec des diamètres de particules de 38,4nm pour le premier et de 28.6nm pour le second. Les résultats expérimentaux dévoilent que la conductivité thermique augmente linéairement avec l'augmentation de la température et dépend de la fraction volumique des nanoparticules dans l'eau.

Xie et *al.* [37] ont examiné l'influence du pH de la solution fluide de base pour différentes tailles de nanoparticules sur l'amélioration de la conductivité thermique du nanofluide d'(Al_2O_3) dispersées dans l'eau, l'éthylène glycol et l'huile. Ils ont découvert que l'amélioration de la conductivité thermique diminue avec l'augmentation de pH.

En 2006, Pracher et *al.* [38] ont mesuré la conductivité thermique à 85°C d'un nanofluide constitué d'eau et de particules d' Al_2O_3 de diamètre 10nm avec une fraction volumique de 0.5%. Ils ont noté qu'à cette température la conductivité du nanofluide était égale à deux fois celle de l'eau.

Li et Peterson [39] ont utilisé des nanoparticules Al_2O_3 de diamètre 36nm avec une fraction volumique de 10% dans l'eau pure à une température de 34.7°C. Ils ont relevé une amélioration de 30% de la conductivité thermique du nanofluide. Sur la base de ces résultats expérimentaux, Li et Peterson ont proposé une relation permettant le calcul de la conductivité thermique du nanofluide (Eau/ Al_2O_3), à savoir :

$$\frac{k_{nf}-k_f}{k_f} = 0,764481\varphi + 0,018688867T - 0.4621 \quad (\text{I.1})$$

Où :

k_{nf} , k_f , φ et T désignent respectivement les conductivités thermiques du nanofluide et du fluide de base, la fraction volumique des nanoparticules et la température.

✓ Les nanoparticules d'oxyde de cuivre

En utilisant des nanoparticules de CuO, de diamètre 36nm avec une fraction volumique de 5% dans de l'eau, Eastman et *al.* [8] ont obtenu une amélioration de la conductivité thermique de 60%, deux fois supérieure à la conductivité thermique obtenue dans les mêmes conditions avec des nanoparticules d' Al_2O_3 .

Lee et *al.* [35] ont trouvé, en mesurant la conductivité thermique des nanofluides avec des nanoparticules de CuO de diamètre 18,6 nm dans de l'eau et dans l'éthylène glycol, que la conductivité thermique du nanofluide utilisé augmente linéairement en fonction de la fraction volumique des nanoparticules.

Das et *al.* [36] ont refait avec des nanoparticules de CuO les mêmes expériences développées pour des nanoparticules d' Al_2O_3 et ils sont parvenus à des résultats analogues, à savoir que la conductivité thermique du nanofluide étudié varie toujours linéairement avec la température.

Li et Peterson [39] ont mené des expérimentations avec des nanoparticules CuO de diamètre 29nm dans l'eau pure avec une fraction volumique 10% et une température de 34.7 C, et ils ont relevé une amélioration de 52% de la conductivité thermique du nanofluide. De plus, ils ont proposé comme pour le cas des nanoparticules d' Al_2O_3 la relation suivante pour le nanofluide (Eau/CuO) :

$$\frac{k_{nf}-k_f}{k_f} = 3.76108 \varphi + 0.017924T - 0.30 \quad (\text{I.2})$$

✓ Nanoparticules de dioxyde de Titane

Les nanoparticules d' Al_2O_3 et de CuO , plus faciles à trouver dans le commerce, ont été les nanoparticules les plus étudiées. Par contre, d'autres nanoparticules ont été plus tardivement étudiées, telle que l'oxyde de Titane (TiO_2), qui ont fait l'objet d'investigation par Pack et Choi [40]. Les résultats obtenus ont montré une amélioration de la conductivité thermique de 10.7 % concernant les nanoparticules de 27 nm dispersées dans l'eau à 4,35 % de fraction volumique. Cette valeur est beaucoup plus faible que les 32% obtenues pour le nanofluide ($\text{Eau}/\text{Al}_2\text{O}_3$) avec la même concentration des nanoparticules. Murshed et *al.* [41] qui ont mesuré la conductivité thermique des nanoparticules (TiO_2) sphérique et cylindrique, ont trouvé que le nanofluide contenant des nanoparticules sphériques de 15 nm conduit à une faible amélioration de la conductivité thermique. Tandis que, pour des nanoparticules cylindriques de 40 nm, ils obtiennent une amélioration allant jusqu'à 33% pour une fraction volumique de 5%.

Le tableau I.1 regroupe des résultats expérimentaux, donnant la conductivité thermique des nanofluides obtenus par plusieurs auteurs, et ceci pour des nanoparticules d'oxydes métalliques de différentes tailles dispersées dans différents liquides porteurs (l'eau, l'éthylène glycol et l'huile) et pour différentes valeurs de fractions volumiques. Ce tableau révèle des discordances entre les résultats obtenus par les différents auteurs et avec le même type de nanoparticules et fluide de base.

1.2.5.2 Les nanoparticules métalliques

✓ Les nanoparticules de cuivre

Les nanoparticules métalliques ont des conductivités thermiques plus grandes que celles des oxydes métalliques correspondantes. La conductivité thermique du cuivre à la température ambiante est environ 700 fois plus grande que celle de l'eau et environ 3000 fois plus grande que celle de l'huile du moteur. Donc, s'attendrait normalement à trouver des valeurs de conductivité thermique de même ordre que celles obtenues avec des oxydes métalliques correspondants et ceci pour des fractions volumiques beaucoup plus faibles. Xuan et Li [42] ont présenté une étude démontrant que la conductivité thermique augmente avec l'augmentation de la fraction volumique. Le rapport de la conductivité thermique du nanofluide (Eau/Cu) et fluide de base augmente de 75% et celui de (Huile/Cu) de 45% quand la fraction volumique des nanoparticules varie entre 2.5% à 7.5%. Théoriquement, Xuan et *al.* [42] ont utilisé le modèle de Hamilton-Crosser pour étudier la conductivité thermique des mêmes nanofluides et ils ont obtenu des résultats très proches des résultats expérimentaux.

Tableau I.1: Résultats donnant les valeurs maximales des conductivités thermiques obtenues pour différents nanofluides avec des nanoparticules sphériques d'oxydes métalliques et différents fluides de base.

<i>Nanofluides</i>	<i>Taille des Nanoparticules (nm)</i>	<i>Fraction Volumique (%)</i>	<i>L'amélioration Maximum de k (%)</i>	<i>Référence</i>
Al ₂ O ₃ + eau	13	4,3	30	Masuda et al. 1993
Al ₂ O ₃ + eau	33	5	30	Eastman et al. 1997
Al ₂ O ₃ + eau	13	4.33	32	Pak et cho. 1998
Al ₂ O ₃ + eau	28	4.5	14	Wang et al. 1999
Al ₂ O ₃ + eau	24.4	4.3	10	Lee et al. 1999
Al ₂ O ₃ + eau	38	4	25	Das et al. 2003
Al ₂ O ₃ + eau	60	5	20	Xie et al. 2002
Al ₂ O ₃ + eau	10	0.5	100	Prasher et al. 2006
Al ₂ O ₃ + eau	20	1	16	Krishnamurthy et al.2006
CuO +eau	36	5	60	Eastman et al. 1997
CuO + eau	28.6	4	36	Das et al. 2003
CuO + eau	18.6	4.3	10	Lee et al. 1999
CuO + eau	23	10	35	Wang et al. 1999
Al ₂ O ₃ +EG	28	8	40	Wang et al. 1999
Al ₂ O ₃ +EG	24.4	5	20	Lee et al. 1999
Al ₂ O ₃ +EG	60	5	30	Xie et al. 2002
CuO + EG	25	5	22.4	Liu et al. 2006
CuO + EG	23	15	55	Wang et al. 1999
Al ₂ O ₃ +huile	28	7	20	Wang et al. 1999
Al ₂ O ₃ + huile	60	5	40	Xie et al. 2002
Al ₂ O ₃ + huile	28	7.5	30	Wang et al. 1999
TiO ₂ + eau	27	4.35	10.7	Pak et Choi. 1998
TiO ₂ + eau	15	5	33	Murshed et al. 2005

En 1997 Eastman et *al.* [8] ont observé une amélioration de 45% de la conductivité thermique par l'ajout de moins de 0.055% en volume des nanoparticules de cuivre de 35 nm dans de l'huile. Également en 2001, ils ont trouvé une amélioration de 40% de la conductivité thermique pour le nanofluide (Cu/Ethylène Glycol) contenant moins de 0.3% en volume de nanoparticules de diamètre inférieur à 10 nm.

✓ Les nanoparticules d'Or et d'Argent

La taille moyenne des nanoparticules d'or (Au) est de 10-20 nm, tandis que, la taille moyenne des nanoparticules d'argent (Ag) est de 60-80 nm.

Patel et *al.* [43] ont étudié les nanofluides (Au/Thiolate/Toluène) et (Au/Citrate/Eau) à une température de 60 °C ; les résultats obtenus montrent qu'il y'a une amélioration de 8.8% de la conductivité thermique pour le premier (avec une fraction volumique de nanoparticules $\phi = 0.011\%$) et une amélioration de 8,3% de la conductivité thermique pour le second (avec un $\phi = 0.00026\%$). Par contre, avec une solution de (Ag- Citrate/Eau), ils sont parvenus à une amélioration de 4.5% pour $\phi = 0.001\%$. Pour le nanofluide (Ag/Eau) la conductivité thermique obtenue est plus faible que celle du nanofluide (Au/Eau), bien que l'argent soit meilleur conducteur de la chaleur que l'or. Cette nette amélioration de la conductivité thermique lors de l'utilisation des nanoparticules d'or par rapport aux particules d'argent pourrait être attribuée à la taille des nanoparticules d'or qui sont de l'ordre de 3 à 8 fois plus petites que celles d'argent. Kumar et *al.* [44] ont rapporté, quant à eux qu'il y a une amélioration de la conductivité thermique de 20% pour $\phi = 0.00013\%$ d'or dans l'eau. Le tableau I.2 regroupe les résultats expérimentaux, donnant la conductivité thermique des nanofluides obtenus par plusieurs auteurs avec des nanoparticules métalliques de différentes tailles dispersées dans différents liquides porteurs (l'eau, l'éthylène glycol et l'huile) et ceci pour différentes valeurs des fractions volumiques de nanoparticules.

Tableau II.2: Valeurs maximales de la conductivité thermique des nanofluides utilisant des nanoparticules métalliques obtenues par différents auteurs.

<i>Les Nanofluides</i>	<i>Taille des nanoparticules</i>	<i>Fraction volumique</i>	<i>L'amélioration maximum de k%</i>	<i>Référence</i>
Cu + huile	35	0.055	45	Eastman et al. 1996
Cu + eau	100	7.5	75	Xuan et Li 2000
Cu + huile	100	7.5	45	Xuan et Li 2000
Cu + EG	10	0.3	40	Eastman et al. 2001
Au + toluène	15	0.011	8.8	Patel et al. 2003
Au + eau	15	0.00026	8.3	Patel et al. 2003
Ag + eau	70	0.001	4.5	Patel et al. 2003
Fe + EG	10	0.55	18	Hong et al. 2006

I.2.5.3 Les nanoparticules non métallique : Les nanotubes de carbone

✓ Structure

Les travaux d'Harold Kroto, Richard Smaley et Robert Curl (Prix Nobel de Chimie en 1996) ont abouti à la découverte d'une nouvelle forme allotropique du carbone, les fullerènes. L'étude de ces nouvelles structures formées de 60 atomes de carbone arrangés sous formes de sphères avait

très vite suscité un vif intérêt dans le milieu des matériaux nanostructurés. C'est en étudiant ces nouvelles structures, synthétisées alors par arc électrique, qu'en 1991 Sumio Iijima observa pour la première fois les nanotubes de carbone (NTC) multi-feuillets noté MWNT (Multi-Walled NanoTube). Ils sont constitués de deux ou plusieurs couches de Graphene. En 1993, il découvrit également des nanotubes mono-feuillets. Le NTC mono-feuillet noté SWNT (Single Walled NanoTube), se présente sous la forme d'un Graphene, enroulé sur lui-même, décrivant une géométrie tubulaire. Si le NTC n'a pas subi de détérioration, une demi-sphère de fullerène forme généralement l'une de ses deux extrémités, tandis que la seconde peut être occupée par une nanoparticule métallique utilisée comme catalyseur pour la synthèse des NTC. Suivant l'orientation des motifs hexagonaux de carbone par rapport à l'axe du tube, il est possible de différencier les divers types de SWNT (Figure I.9).

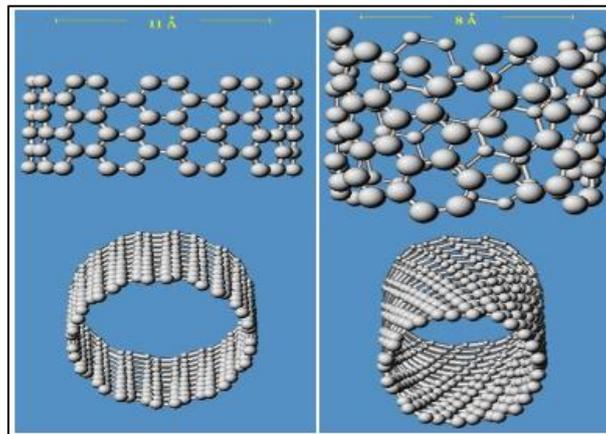


Figure I.9: Différentes structures des nanotubes identifiées [7].

✓ Propriété thermique des nanotubes de carbone

Les travaux théoriques et expérimentaux ont permis la détermination de la conductivité thermique de ces nanotubes de carbone (3000 W/m^{°K} pour les nanotubes de carbone multi-feuillets ou multiwall (MWNTCs) et 6000 W/m^{°K} pour les nanotubes de carbone single-wall (SWNTCs) [45]. Ce sont les études portant sur les nanofluides à base de nanotubes de carbone qui ont montré les augmentations de conductivité thermique les plus élevées. Ces dernières sont de l'ordre de plus de 160% pour des concentrations en volume de 1% (Choi en 2001). Une manière simple de représenter l'effet de nanotubes de carbone en solution est de considérer les nanotubes en suspension comme étant de nano-ponts thermiques susceptibles de conduire rapidement l'énergie d'un point à l'autre de l'échantillon comme le montre la figure I.10.

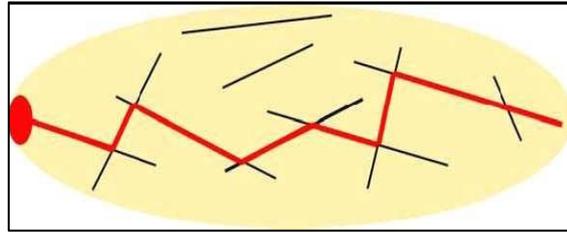


Figure I.10: Explication schématisée de la création d'un réseau de ponts thermiques (trait rouge) créé par une dispersion de nano-fibres (trait noir) dans un liquide (Beige) qui permet la propagation de la chaleur d'une zone chaude (ovale rouge) vers une zone froid [7].

Cette augmentation de conductivité thermique peut être prédite par la théorie du milieu effectif qui prévoit de fortes augmentations de conductivité thermique pour des fluides contenant des nanoparticules ayant un grand rapport d'aspect (Kebinski 2005). Cette théorie permet de calculer l'augmentation de la conductivité thermique du liquide en fonction du rapport d'aspect des nanotubes utilisés. Elle prédit que la conductivité thermique du nanofluide devrait augmenter fortement avec le rapport d'aspect des nanotubes.

L'augmentation de conductivité thermique prévue par cette théorie (jusqu'à 6000%) est largement supérieure à celle obtenue expérimentalement (150%). Cela pourrait être expliqué par la forte résistance inter-faciale entre le nanotube et le liquide, résultant de la faible affinité entre les liquides et les nanotubes de carbone qui provoquent une déplétion des molécules de liquide environnant autour du nanotube. Ceci a pour effet de réduire le couplage thermique entre les nanotubes et le liquide environnant, ce qui réduit la conductivité thermique du mélange. Afin de limiter cet effet, des travaux sont actuellement en cours pour obtenir une meilleure adéquation entre le nanotube et le fluide porteur. Ces travaux de recherche permettent d'une part d'améliorer la stabilité de la suspension et d'autre part l'obtention de nanofluides meilleurs conducteurs de la chaleur. En revanche, les molécules greffées à la surface du nanotube peuvent également induire une résistance inter-faciale supplémentaire [46].

La principale difficulté rencontrée avec les nanofluides à base de nanotubes de carbone la dispersion de manière stable dans le temps les nanotubes de carbone dans le liquide de base Wang et *al.* [47]. Le rapport d'aspect des nanotubes, les méthodes de préparation et d'ensemencement sont différents d'une publication à une autre, entraînant une grande différence entre les valeurs des conductivités thermiques mesurées pour les nanofluides avec des nanotubes de carbone. Ainsi la conductivité thermique augmente de 10% pour une concentration de 1% de nanotube dans l'eau (Xie 2003), de 38% pour une concentration de 0.6% de nanotubes dans l'eau (Assael 2005) ou encore de 150% pour une concentration de 1% de nanotubes dans l'Éthylène Glycol (Choi 2001).

L'utilisation de nanotube de carbone en suspension Choi et *al.* [2], où de multi couches de nanotubes de carbone de taille de 25 nm et une longueur de 50 μ m sont dispersées dans de l'huile Polyoléfine (PAO) à la température ambiante. Une amélioration de rapport de conductivité thermique de plus de 160% a été observée avec un $\phi = 1\%$, cela indique que l'interaction entre les fibres conduit à une plus grande valeur de la conductivité thermique.

D'autres études ont conduit à des résultats différents pour des nanotubes de carbone dispersés dans de l'eau. Xie et *al.* [48] y ont dispersé des (MNTC). L'amélioration de la conductivité thermique du nanofluide obtenue est de 20% pour une concentration de 1% de volume.

Wen et Ding [49] ont mesuré l'amélioration de (MNTCs) en suspension dans l'eau en fonction de la température et de la concentration. Ils ont trouvé, qu'en dessous de 30°C, la conductivité thermique du nanofluide augmente linéairement avec l'augmentation de la température. L'amélioration maximum obtenue est de 31% pour $\phi = 0.84\%$ et à la température de 60°C. La même expérience a été menée par Ding et *al.* [50] qui ont trouvé une amélioration de 80% pour $\phi = 1\%$ et à une température de 30°C. Assael et *al.* [51] ont obtenu 38% pour une fraction volumique de 0.6% de nanotubes dans l'eau ou encore de 150% pour une concentration de 1% de nanotubes dans l'éthylène glycol.

Tableau I.3: Valeurs mesurées de la conductivité thermique des nanofluides avec des nanotubes de carbone pour différents fluides de base et pour différentes valeurs de la fraction volumique.

<i>Les Nanofluides</i>	<i>Fraction volumique ϕ</i>	<i>(k_{nf}/k_f)</i>	<i>Référence</i>
MWCNTs/PAO	1	160	Choi et al. 2001
MWCNTs/eau	1	6	Xie et al. 2003
MWCNTs/EG	1	12	Xie et al. 2003
MWCNTs/Decène	1	20	Xie et al. 2003
MWCNTs/eau	0.84	21	Wen et Ding 2004b
MWCNTs/PAO	0.35	200	Yang et al. 2006
DWCNTs/Eau	1	8	Assael et al. 2004 et 2005
MWCNTs/Eau	0.6	34	Assael et al. 2004 et 2005
MWCNTs/Huile synthétique	2	30	Liu et al. 2005
MWCNTs/EG	1	12.4	Liu et al. 2005

1.2.6 Domaines d'applications des nanofluides

Les nanofluides peuvent être employés pour améliorer le transfert de chaleur et delà l'efficacité énergétique dans plusieurs systèmes thermiques. Dotés de caractéristiques thermiques exceptionnelles, les nanofluides constituent une solution attractive dans de nombreuses applications. Selon leur utilisation, les nanofluides sont classés en nanofluides chimiques, nanofluides tribologiques, nanofluides surfactants et de revêtement, nanofluides caloporteurs, nanofluides

environnementaux (nettoyage de la pollution), nanofluides de procédé d'extraction, nanofluides pharmaceutiques et biologiques et nanofluides médicaux (interaction tissu–cellule).

Dans cette section, quelques exemples d'applications seront présentés tel que le transport, la micro-électronique, la défense, le nucléaire, l'espace et le biomédicale [52].

1.2.6.1 Refroidissement des systèmes thermiques

Le refroidissement des systèmes thermiques a été étudié par plusieurs chercheurs, comme Tzeng et *al.* [53] qui ont dispersé des nanoparticules de CuO et Al₂O₃ dans l'huile de refroidissement du moteur de transmission, leurs résultats expérimentaux montrent que CuO a le meilleur effet de transfert de chaleur. Également, Akhavan-Behabadi et *al.* [54] ont révélé une amélioration significative du transfert de chaleur par condensation de l'écoulement du nano-réfrigérant R600/POE/CuO dans un tube horizontal lisse.

Les nanofluides ont un point d'ébullition élevé et par conséquent peuvent être utilisés pour augmenter la température de fonctionnement du liquide de refroidissement, puis rejeter davantage de chaleur par le biais du système de refroidissement existant, comme le montre les études effectuées par Yang et *al.* [55]. Ces derniers ont mené des expériences sur un tube ondulé afin de décrire les performances en ébullition du nanoréfrigérant MWCNT/R141b. De même des expériences sur les nanoréfrigérant R600a-CuO-POE dans un tube horizontal ont été menées par Darzi et *al.* [56].

1.2.6.2 Refroidissement des systèmes électroniques

Un refroidissement efficace est l'un des principaux défis dans le domaine de l'électronique. Il a été démontré que les microprocesseurs atteignent le double de leur capacité de calcul lorsqu'on utilise un refroidissement à base de nanofluides. Les dispositifs électroniques avancés font face à des défis de gestion thermique dus au niveau élevé de génération de chaleur et à la réduction de la surface disponible pour l'évacuation de la chaleur. Parmi les études effectuées, on a Tsai et *al.* [57] qui ont employé un nanofluide à base d'eau pour refroidir une unité centrale de traitement dans un microordinateur, ils ont remarqué qu'au même volume de charge, il y a une réduction significative de la résistance thermique du caloduc avec nanofluide par rapport à l'eau. De leur côté, Ma et *al.* [58] ont étudié l'effet du nanofluide sur les possibilités de transport de la chaleur d'un caloduc d'oscillation, et ils ont démontré qu'à la puissance d'entrée de 80 W et seulement pour une concentration volumique de $\varphi=1\%$, la différence de température entre le vaporisateur et le condensateur est de 16.6°C.

1.2.6.3 Refroidissement des systèmes d'applications militaires

Les exemples d'applications militaires incluent le refroidissement de l'électronique de puissance et les armes d'énergie dirigée. Ces derniers impliquent des flux thermiques très élevés

($Q > 500$ à 1000 W/cm^2). Les nanofluides sont susceptibles de fournir le refroidissement requis dans de telles applications ainsi que dans d'autres systèmes militaires, notamment les véhicules militaires, les sous-marins et les diodes laser de haute puissance [52].

1.2.6.4 Refroidissement des systèmes spatiaux

Des recherches plus poussées sur les nanofluides conduiront certainement au développement de la prochaine génération de dispositifs de refroidissement incorporant des nanofluides pour des systèmes électroniques à très haute chaleur, offrant ainsi la possibilité de simplifier les exigences de refroidissement pour les applications spatiales. You et *al.* [59] et Vassallo et *al.* [60] ont effectué des études pour montrer que la présence des nanoparticules dans le fluide de refroidissement en électronique joue généralement un rôle très important dans les applications de l'espace où la densité de puissance est très élevée.

1.2.6.5 Refroidissement des systèmes nucléaires

La technologie des nanofluides peut être aussi utilisée dans le secteur de l'énergie nucléaire. Les nanofluides peuvent être utilisés comme fluide de refroidissement des réacteurs à eau sous pression et également pour les liquides de refroidissement des systèmes de refroidissement d'urgence du cœur des réacteurs à eau sous pression et des réacteurs à eau par ébullition. L'utilisation d'un nanofluide dans les accumulateurs des systèmes de refroidissement d'urgence du cœur et l'injection en sécurité peuvent ainsi augmenter les marges de température maximale. Les nanofluides peuvent aussi jouer le rôle de fluide de refroidissement pour la rétention du noyau fondu lors d'accidents graves dans les réacteurs à eau légère à haute puissance [52].

1.2.6.6 La biomédecine et l'activité antibactérienne

Les nanofluides et les nanoparticules ont beaucoup d'applications en biomédicale. Par exemple, pour éviter quelques effets secondaires des méthodes traditionnelles de traitement du cancer, les nanoparticules à base de fer ont été employées comme transporteur des médicaments. Pareillement, pour une chirurgie plus sûre et pour produire un refroidissement efficace autour de la région chirurgicale, Jordan et *al.* [61] ont effectué une étude où les nanofluides pourraient être employés pour produire une température plus élevée dans le but de tuer les cellules cancéreuses sans affecter les cellules saines voisines.

Des recherches sur l'activité antibactérienne de nanoparticules de CuO ont montré qu'elles possédaient une activité antibactérienne contre quatre souches bactériennes. La taille des nanoparticules était inférieure à celle des pores de la bactérie, ce qui lui donnait la propriété unique de traverser la membrane cellulaire sans aucune entrave. On pourrait émettre l'hypothèse que ces

nanoparticules formaient des complexes stables avec des enzymes vitales à l'intérieur des cellules, ce qui entraverait le fonctionnement cellulaire, entraînant ainsi leur mort [52].

1.2.6.7 D'autres applications

Les nanoréfrigérants et les nanolubrifiants sont des types spéciaux de nanofluides. Ces nano-additifs améliorent les performances du système de réfrigération, et peut aider à augmenter l'efficacité du système. Les nanofluides ont potentiellement des applications dans la majorité des industries de transformation, telles que les matériaux, la production chimique, la nourriture, la boisson, le pétrole et le gaz. Dans l'industrie de l'énergie renouvelable, les nanofluides sont utilisés pour augmenter le transfert de chaleur à partir des capteurs solaires aux réservoirs de stockage. Le remplacement de l'eau de refroidissement et de chauffage par des nanofluides pourrait permettre d'atteindre de grandes économies d'énergie associées à d'importantes réductions des émissions polluantes. Le stockage de l'énergie thermique sous forme de chaleur sensible et latente est devenu un aspect important de la gestion de l'énergie, l'accent étant mis sur l'utilisation et la conservation efficaces de la chaleur résiduelle et de l'énergie solaire dans l'industrie et les bâtiments. Les performances thermiques des matériaux à changement de phase à base de nanofluides indiquent un potentiel de substitution aux matériaux à changement de phase classiques dans les applications de stockage à froid [52, 62].

I.3 Caractéristiques thermophysiques des nanofluides

Les propriétés thermophysiques des solutions telles que la masse volumique, la chaleur spécifique, l'expansion thermique, la viscosité et la conductivité thermique sont profondément modifiées par l'ajout des nanoparticules. De nombreux paramètres caractérisant ces nanoparticules peuvent avoir un effet notable sur les valeurs des paramètres thermophysiques du nanofluide obtenus (la nature des nanoparticules, leur taille, la fraction volumique ϕ , la conductivité du fluide de base et celle des nanoparticules, la température du milieu, etc.). De nombreuses recherches théoriques et expérimentales ont été menées, lors de ces deux dernières décennies, en vue de mieux caractériser les propriétés physiques des nanofluides, cependant ceci est encore loin d'être satisfaisant. Les résultats expérimentaux de l'amélioration de la conductivité thermique en fonction de ces paramètres sont résumés dans les tableaux (II.1-II.4) donnés en Annexe A.

La conductivité thermique et la viscosité dynamique sont les deux propriétés thermophysiques des nanofluides les plus étudiées comme l'atteste le nombre de modèles développés pour le calcul de ces deux grandeurs. Relativement, la masse volumique et la chaleur spécifique des nanofluides suscitent peu d'intérêt, notamment sur le plan expérimental [52].

I.3.1 Conductivité thermique des nanofluides

La conductivité thermique, λ (W/m.K), exprime la capacité d'un matériau de conduire ou de transmettre de la chaleur. Elle est définie comme la quantité de chaleur transférée par unité de surface et de temps sous un gradient de température de 1K par mètre [63].

La conductivité thermique est la propriété la plus importante des nanofluides car la principale raison de l'ajout de nanoparticules dans le fluide de base est justement d'augmenter sa conductivité thermique. C'est pour cela, qu'une grande partie des travaux traitant les nanofluides porte sur la quantification de l'augmentation de leur conductivité thermique.

D'ailleurs, l'objectif de ces travaux est de mesurer cette conductivité thermique afin de choisir les nanoparticules et le fluide porteur le plus approprié et ceci pour une conductivité thermique la plus élevée possible. Les travaux ont également porté sur la façon de prédire l'augmentation de conductivité thermique par rapport à celle des nanoparticules et du fluide porteur, en fonction de la taille et de la forme de ces nanoparticules. Et ceci en proposant différentes relations prédisant le rapport de conductivité thermique du nanofluide sur celle du fluide à savoir:

$$\frac{k_{nf}}{k_f}$$

I.3.1.1 Méthodes de mesures de la conductivité thermique

Différentes techniques de mesure de la conductivité thermique des nanofluides ont été utilisées, la majorité des expériences de mesure de la conductivité thermique dans les nanofluides sont réalisées à l'aide de la méthode du fil chaud transitoire [64-67].

D'autres techniques courantes sont employées comme la méthode d'oscillation de la température, la technique de déviation du faisceau optique [36], la méthode 3-oméga [68] et la technique de l'onde thermique [69]. Certaines de ces méthodes ne sont peut-être pas forcément valides lorsqu'elles sont appliquées aux nanofluides, car aucune d'entre elles n'a été initialement conçue et destinée aux nano-suspensions. Des différences significatives de valeurs de la conductivité thermique mesurée par ces différentes techniques existent, comme l'a signalé Buongiorno et al. [70].

I.3.1.2 Les paramètres influençant la conductivité thermique des nanofluides

Dans la littérature, on trouve un nombre important d'études montrant que la conductivité thermique des nanofluides dépend de la nature du liquide de base, de la nature du matériau constitutif des nanoparticules, de la taille, de la forme et de la concentration volumique des nanoparticules, de la température, de la présence d'additifs ainsi que du pH du mélange comme le montre la figure I.11[5, 10, 71].

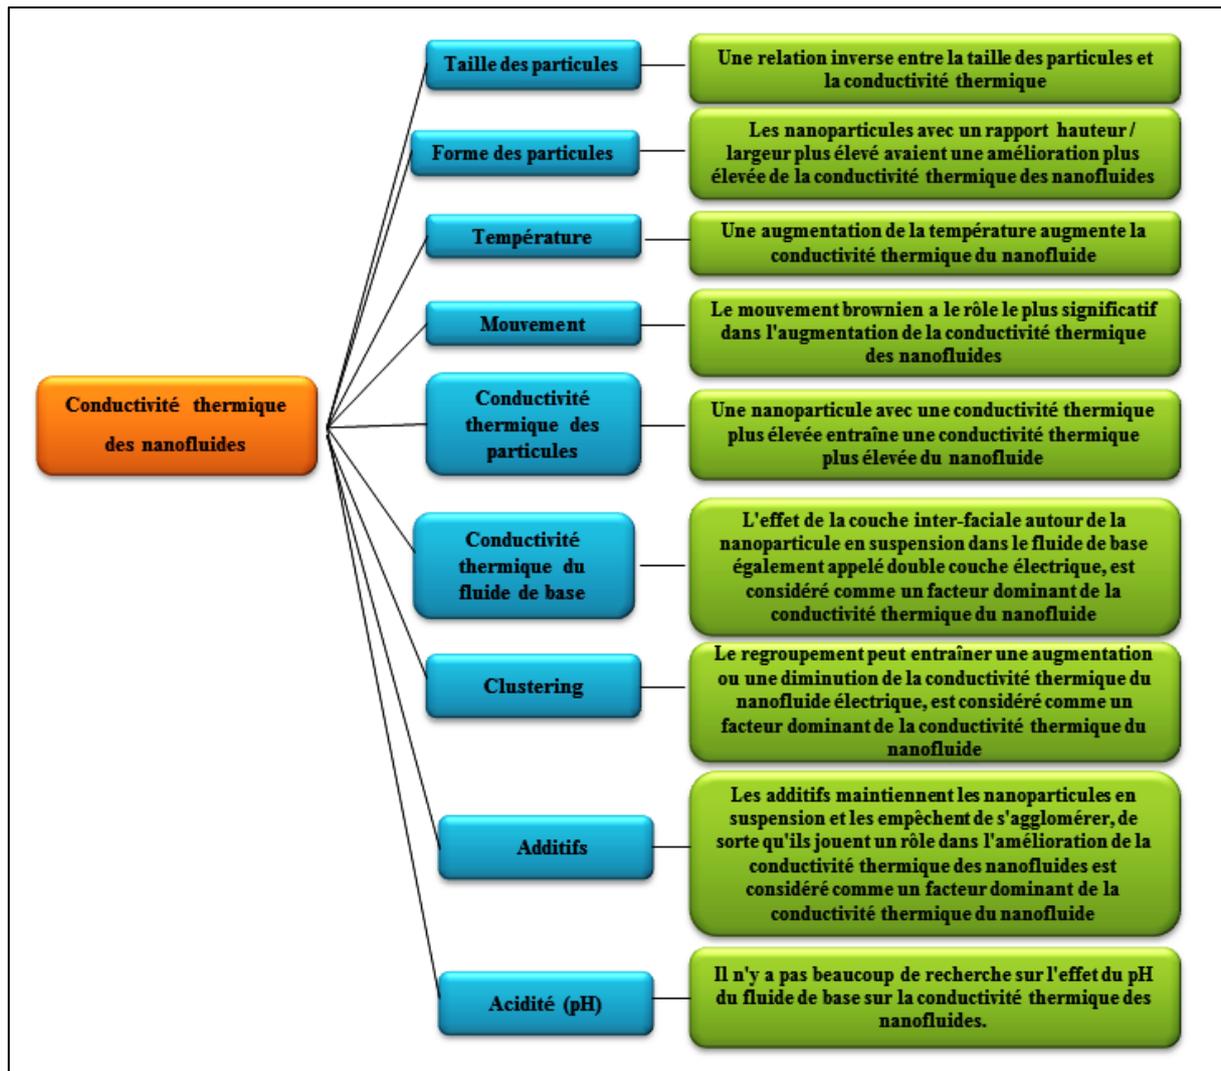


Figure I.11: Paramètres affectants la conductivité thermique des nanofluides [72, 73].

L'influence des différents paramètres sur la conductivité thermique des nanofluides est présentée dans la partie I de l'Annexe A.

1.3.1.3 Modèles de la conductivité thermique

Etant donné que les nanoparticules à haute conductivité thermique augmentent remarquablement la conductivité thermique de nanofluides, plusieurs chercheurs ont développé différents modèles d'estimation de cette dernière. En plus de nombreuses expériences ont aussi été menées afin de valider ces modèles analytiques, et ceci en les comparant aux résultats obtenus expérimentalement. Ces modèles sont des outils de prédictions et d'appréhension des mécanismes de transfert thermique au sein des nanofluides [3].

Il existe un panel important de modèles de calcul de la conductivité thermique apparente dans un nanofluide; et dans ce qui suit nous présentons succinctement quelques-uns de ces modèles. Ces modèles recouvrent en réalité deux grands types d'approches, d'une part par analogie électrique

et d'autre part par résolution exacte de l'équation de chaleur. En fait, seule l'expérimentation physique permet d'obtenir une évaluation précise de la conductivité des nanofluides [7].

a) *Modèles de type Maxwell*

✓ **Modèle de Maxwell**

Maxwell [32] a été l'un des premiers à étudier analytiquement la conduction thermique dans les particules en suspension en ignorant les effets d'interactions entre ces particules. L'équation de Maxwell est obtenue en résolvant l'équation de Laplace pour le champ de température, et elle est donnée par :

$$k_{nf} = k_f + 3\varphi \frac{k_s - k_f}{k_s + 2k_f - \varphi(k_s - k_f)} k_f \quad (I.3)$$

Notons que le modèle de Maxwell est satisfaisant pour les suspensions contenant des particules sphériques de faibles concentrations volumiques, toutefois il ne tient pas compte de l'effet de la taille ni de la forme des particules.

✓ **Modèle de Hamilton-Crosser**

Le modèle de Hamilton-Crosser [74] est une extension du modèle de Maxwell. Il concerne les particules de forme quelconque. Pour prendre en compte cette diversité de forme, Hamilton introduit un facteur géométrique appelé sphéricité (ψ) qui fait référence à la géométrie sphérique. Ce coefficient est défini comme étant le rapport de la surface de la sphère ayant le même volume que les nanoparticules et la surface d'une nanoparticule.

La conductivité thermique apparente du milieu est donnée par l'expression suivante :

$$\frac{k_{nf}}{k_f} = \frac{k_s + (n-1)k_f - (n-1)(k_f - k_s)\varphi}{k_s + (n-1)k_f + (k_f - k_s)\varphi} \quad (I.4)$$

Où n est un facteur de forme empirique donné par :

$$n = \frac{3}{\psi}, \quad (n = 3 \text{ pour les particules sphériques et } n = 6 \text{ pour les particules cylindriques.})$$

Pour $\psi = 1$ (particules sphériques), le modèle de Hamilton-Crosser est identique au modèle de Maxwell.

b) *Modèles des nano-couches*

✓ **Modèle de Yu et Choi**

Une autre expression pour calculer la conductivité thermique a été introduite par Yu et Choi [75]. Ils ont proposé de modéliser les nanofluides comme étant un liquide de base et des particules solides séparés par une couche nanométrique, cette couche agit comme un pont thermique entre le fluide et les nanoparticules. De plus, ils ont supposé que la conductivité thermique de la couche nanométrique est plus grande que celle du liquide. Et ils ont proposé la relation suivante :

$$\frac{k_{nf}}{k_f} = \frac{k_s + 2k_f + 2(k_s - k_f)(1+\beta)^3\varphi}{k_s + 2k_f - (k_s - k_f)(1+\beta)^3\varphi} \quad (I.5)$$

Où β est le rapport de l'épaisseur de la couche nanométrique sur le rayon des particules [3].

✓ **Modèle de Bruggeman**

Le modèle proposé par Bruggeman [76] semble mieux estimer certains résultats expérimentaux comparé aux autres modèles [77], surtout pour le cas des nanoparticules sphériques de différentes concentrations.

$$k_{nf} = \frac{1}{4}[(3\varphi - 1)k_s + (2 - 3\varphi)k_f] + \frac{k_f}{4}\sqrt{\Delta} \quad (I.6)$$

Avec :

$$\Delta = \left[(3\varphi - 1)^2 \left(\frac{k_s}{k_f} \right)^2 + (2 - 3\varphi)^2 + 2(2 + 9\varphi - 9\varphi^2) \left(\frac{k_s}{k_f} \right) \right] \quad (I.7)$$

c) **Modèles basés sur le mouvement Brownien**

Le mouvement Brownien est une description mathématique du mouvement aléatoire d'une particule de taille importante immergée dans un fluide et qui n'est soumise à aucune autre interaction qu'avec les petites molécules de ce fluide. Lorsqu'on considère un nanofluide, on a un transport d'énergie directement par les nanoparticules ainsi que par la micro-convection qui est due au mélange du fluide autour de ces nanoparticules.

Plusieurs modèles ont été développés pour la détermination de la conductivité thermique des nanofluides basée sur le mouvement Brownien. Deux de ces modèles sont cités ci-dessous.

✓ **Modèle de Choi et Jang**

Choi et Jang [78] ont modélisé la conductivité thermique des nanofluides tenant en compte l'effet du mouvement Brownien des particules. Le modèle proposé ne dépend pas seulement de la conductivité des nanofluides, mais aussi de la taille et de la température des nanoparticules. Le transport d'énergie a été considéré comme étant composé de quatre types de transport : conduction thermique du fluide de base, conduction de chaleur dans les nanoparticules, collisions entre les nanoparticules (due au mouvement Brownien) et micro-convection causée par le mouvement aléatoire des nanoparticules. Toutefois, les collisions entre les particules sont considérées comme négligeables par rapport aux autres formes de transport.

Selon cette étude l'expression suivante a été proposée :

$$k_{nf} = k_f(1 - \varphi) + k_p^*\varphi + 3C_1 \frac{d_f}{d_p} k_f Re_d^2 Pr_f \varphi \quad (I.8)$$

Où C_1 est une constante de proportionnalité, d_f le diamètre de la molécule de fluide, d_p le diamètre des nanoparticules, Pr_f le nombre de Prandtl du fluide de base.

k_p^* est définie comme :

$$k_p^* = \beta k_p \quad (I.9)$$

Où β est le nombre de Reynolds défini comme une constante:

$$Re_d = \frac{\overline{C_{R.M.}} d_p}{\nu_f} \quad (I.10)$$

Avec $\overline{C_{R.M.}}$ comme la vitesse du mouvement aléatoire des nanoparticules et ν_f la viscosité cinématique du mouvement aléatoire du fluide de base. $\overline{C_{R.M.}}$, qui peut être déterminée de la façon suivante :

$$\overline{C_{R.M.}} = \frac{D_0}{\lambda_f} \quad (I.11)$$

Où λ_f est le parcours moyen libre des molécules de fluide de base et D_0 est le coefficient de diffusion de la particule qui peut être calculé par l'expression d'Einstein suivante [78]:

$$D_0 = \frac{k_B T}{3\pi\mu_f d_p} \quad (I.12)$$

Où k_B est la constante de Boltzmann avec T en Kelvins, et μ_f la viscosité dynamique du fluide de base [78].

✓ **Modèle de Koo et Kleinstreuer**

Koo et Kleinstreuer [79] ont considéré que la conductivité thermique des nanofluides est composée de deux parties :

$$k_{nf} = k_{statistique} + k_{brownien} \quad (I.13)$$

Où : $k_{statistique}$ est l'augmentation de la conductivité thermique due aux nanoparticules et $k_{brownien}$ tient compte de l'effet du mouvement brownien. Pour la partie statique on a la formule de Maxwell et en conséquence, l'expression suivante a été proposée :

$$k_{brownien} = 5 \cdot 10^4 \tilde{B} \varphi \rho_f c_{p,f} \sqrt{\frac{k_B T}{\rho_p d_p}} \tilde{F}(\varphi, T) \quad (I.14)$$

Où ρ_p , ρ_f sont la densité de la particule et du nanofluide respectivement, T la température en Kelvin et $c_{p,f}$ est la capacité calorifique du fluide de base. Un élément additionnel \tilde{B} a été introduit pour tenir compte de l'effet du mouvement des particules. En général, \tilde{B} est lié au mouvement des particules, il dépend donc de la fraction volumétrique mais aussi de la température, de la forme et des propriétés de matériaux (Koo et Kleinstreuer [79]).

Koo et Kleinstreuer, supposent que \tilde{B} dépend seulement de la concentration volumétrique et que tout autre dépendance est incluse dans le paramètre \tilde{F} ; cela signifie que le terme \tilde{B} devient plus effectif avec l'augmentation de la fraction volumétrique. Le paramètre \tilde{F} qui a été obtenu en utilisant les résultats de Das et al. [36] pour le nanofluide à base de CuO, a été introduit afin d'inclure les autres dépendances du modèle. Ces deux paramètres sont déterminés expérimentalement. Dans le travail de Koo et Kleinstreuer \tilde{F} a la forme :

$$\tilde{F} = (-134.63 + 1722.3\varphi) + (0.4705 - 6.04\varphi)T \quad (\text{I.15})$$

d) Modèles basées sur les grappes

Les nanoparticules sont connues pour leurs tendances à former des grappes (Prasher et al [38]). Une approche pour modéliser ces grappes est donnée par la théorie des fractals (Wang et al [47]), celle-ci suppose que la formation des grappes est due au transport rapide de la chaleur sur une distance (relativement grande) car la chaleur est conduite plus rapidement par des particules solides en comparaison au liquide.

Le paragraphe suivant présente un modèle théorique fondé sur les grappes de nanoparticules. Le modèle considère également l'effet du mouvement brownien.

✓ Modèle de Xuan et al

Xuan et al. [80] ont proposé l'expression suivante de la conductivité thermique, basé le mouvement brownien ainsi que sur les grappes des nanoparticules :

$$k_{nf} = k_f \frac{k_p + 2k_f + 2(k_p - k_f)\varphi}{k_p + 2k_f - (k_p - k_f)\varphi} + \frac{\rho_p \varphi C_{p,p}}{2k_f} \sqrt{\frac{k_B T}{3\pi r_{cl} \mu_f}} \quad (\text{I.16})$$

Ici, r_{cl} est le rayon apparent des grappes de nanoparticules, qui est déterminé expérimentalement, T la température en Kelvin, μ_f la viscosité dynamique du fluide de base (comme calculée par Li et Xuan [42]). Le premier terme de l'expression de droite correspond à la formule de Maxwell pour la conductivité thermique et le deuxième ajoute l'effet du mouvement aléatoire des nanoparticules.

Afin d'examiner la contribution de ce dernier terme, des valeurs pour des nanoparticules de Cu de 50 nm avec un $\varphi = 0:03$, cette contribution est de 11% lorsque les grappes se forment et de 17% quand les grappes ne se forment pas. Dans le cas où $\varphi = 0:04$, les contributions sont de 14% et 24% respectivement. Il a été aussi indiqué que le mouvement Brownien des nanoparticules devient plus efficace avec l'amélioration de la température. D'autre part, au fur et à mesure que les nanoparticules et les grappes deviennent plus grandes, le mouvement aléatoire devient plus lent et cela diminue l'amélioration de la conductivité thermique [10].

✓ Modèle de Chen et al

Un autre modèle qui considéré l'effet des grappes est le modèle proposé par Chen et al. [81]. La formule proposée pour le calcul la conductivité thermique est une modification de la formule de Hamilton et Crosser [74] :

$$k_{nf} = k_f \frac{k_{cl} + (n-1)k_f - (n-1)(k_f - k_{cl})\varphi_{cl}}{k_{cl} + (n-1)k_f + (k_f - k_{cl})\varphi_{cl}} \quad (\text{I.17})$$

Où k_{cl} et φ_{cl} sont la conductivité thermique et la fraction volumétrique des grappes, respectivement. Les valeurs de n sont égales à 3 pour les particules sphériques et 5 pour les particules cylindriques.

$$\varphi_{cl} = \varphi \left(\frac{r_{cl}}{r_p} \right)^{3-D} \quad (I.18)$$

Avec r_{cl} et r_p sont les rayons de grappes et de nanoparticules respectivement. D correspond à l'indice fractal, avec une valeur prise de 1,8. Les valeurs r_{cl} et r_p sont égales à 2,75 et 3,34 pour le (TiO₂/Eau) et (TiO₂/Ethylène Glycol) de forme sphérique. L'estimation de k_{cl} est plus complexe puisqu'il dépend de la forme géométrique des particules. Bruggeman [76] a calculé l'expression pour les particules sphériques pendant que Nan et al. [5] l'ont calculé pour les particules cylindriques.

e) Les nanofluides contenant des nanotubes de carbone

Généralement, les particules des nanotubes de carbone peuvent être considérées comme des sphéroïdes allongées qui satisfont $a \gg b-c$. Par conséquent, de nombreux modèles développés pour les suspensions sphéroïdes allongées peuvent être utilisés pour estimer la conductivité thermique effective des nanofluides à base de nanotubes de carbone. Grâce à cette approche, Nan et al. [82], ont proposé une équation approximative obtenue à partir de l'équation de Fricke [83,84] et ceci en utilisant la condition que k_R est beaucoup plus grande que K_a :

$$k_{eff} = k_f + \frac{1}{3} \varphi \frac{k_s}{1 + Rk_s/a} \quad (I.19)$$

Nan et al. [85] dans leurs travaux ont négligés l'effet de la résistance de contact :

$$k_{eff} = k_f + \frac{1}{3} \varphi k_s \quad (I.20)$$

1.3.1.4 Résultats expérimentaux et modèles de la conductivité thermique

La figure I.12 présente une comparaison des résultats de k_{nf}/k_f (rapport de conductivité thermique du nanofluide sur celle du fluide) en fonction de φ pour des nanofluides (Al₂O₃/Eau), obtenus par différents modèles. Il ressort de cette comparaison que le modèle Hamilton-Crosser donne des prédictions plus élevées. Tandis que celles du modèle de Yu-Choi se situent entre celles du modèle de Hamilton-Crosser et de Maxwell.

La figure I.13 présente le rapport conductivité thermique k_{nf}/k_f en fonction de φ pour des nanofluides (Al₂O₃/Eau), obtenus à partir de différents travaux expérimentaux. Ils sont comparés aux résultats des modèles de Hamilton-Crosser et Yu-Choi et ceci pour une valeur de

($\psi = 0.7$). On remarque que les résultats obtenus par ces modèles sont loin de ceux obtenus expérimentalement par Massuda et *al.* [33] et Eastman et *al.* [8]. Par contre, ils sont en bon accord avec ceux obtenus par Xie et *al.* [37] et Lee et *al.* [35] et ceci pour les faibles valeurs de ϕ .

La figure I.14 présente la conductivité thermique du nanofluide (CuO/Eau) prédite par le modèle de (Hamilton-Crosser) comparée aux résultats expérimentaux trouvés dans la littérature. On constate que les résultats du modèle de Hamilton-Crosser sont en très bon accord avec ceux obtenus par Lee et *al.* [35] ainsi que ceux de Das et *al.* [36]. Par contre ils diffèrent sensiblement de ceux mesurés par Eastmen et *al.* [9].

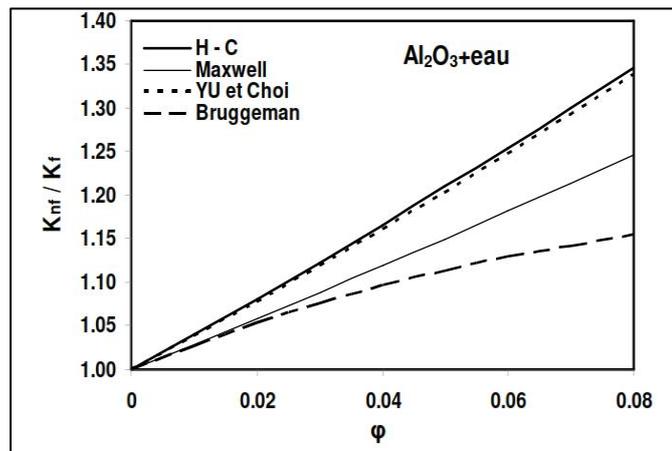


Figure I.12: Comparaison des résultats prédits du modèle de H-C avec ceux d'autres modèles pour les nanofluide ($\text{Al}_2\text{O}_3/\text{Eau}$) [7].

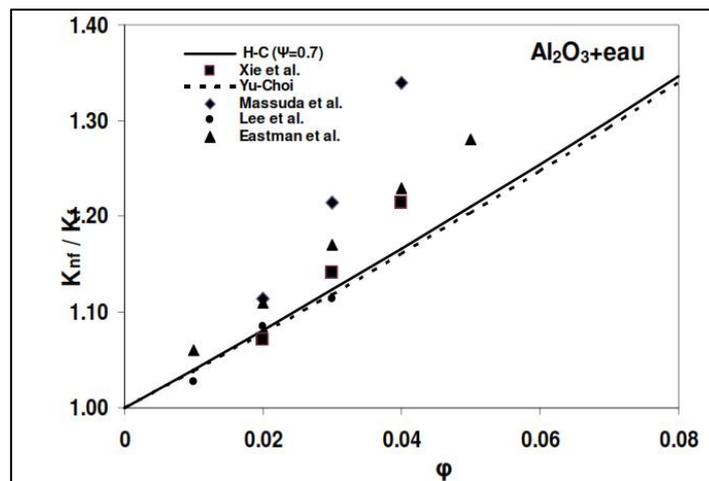


Figure I.13: Comparaison des résultats expérimentaux de nanofluides ($\text{Al}_2\text{O}_3/\text{Eau}$) et ceux obtenus à partir des modèles de H-C et de Yu-Choi [7].

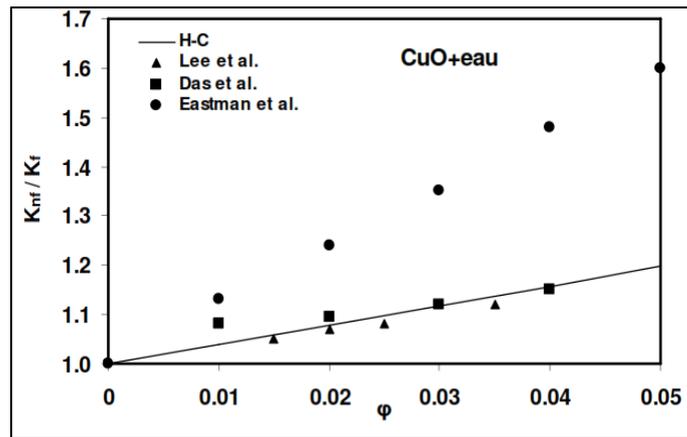


Figure I.14: Comparaison entre les résultats prédits du modèle de H-C avec ceux obtenus expérimentalement pour les nanofluides (CuO/Eau) [7].

La figure I.15 montre l'influence de la fraction volumique des nanoparticules sur la conductivité thermique du nanofluide (Cu/Eau). On remarque que les résultats prédits par le modèle de H-C sont satisfaisants (si l'on prend une sphéricité $\psi = 0.3$), par contre pour $\psi=0.7$ les résultats sont loin de l'être.

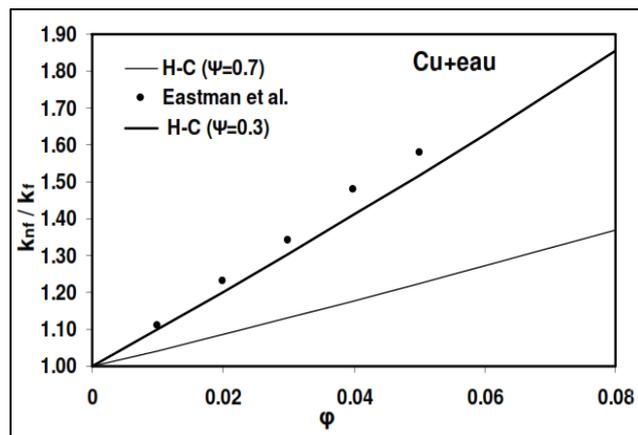


Figure I.15: Comparaison entre les résultats du modèle de H-C avec des résultats expérimentaux pour les nanofluides (Cu/Eau) et pour deux valeurs de ψ [7].

Les suspensions à base de nanotubes de carbone donnent de plus grandes conductivités thermiques comparées à celles des suspensions de nanoparticules métalliques. Ceci s'explique évidemment par les valeurs élevées de la conductivité thermique de ces nanotubes de carbones.

La conductivité thermique des nanofluides (Nanotubes de Carbone/Eau) augmente avec les fractions volumiques et ceci pour ϕ variant de 0% à 8%. En utilisant comme conductivité thermique du nanotube de carbone ($k_s = 2500 \text{ W.m}^{-1} \cdot \text{K}^{-1}$), on obtient pour une fraction volumique de 8% une amélioration de la conductivité thermique de 74% figure I.16.

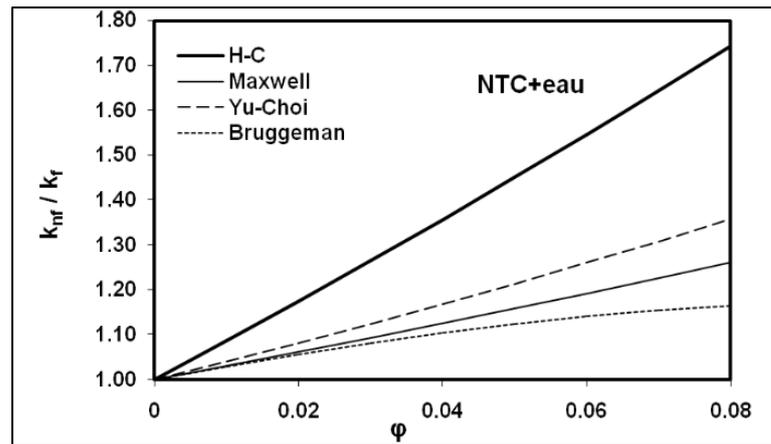


Figure I.16: Comparaison des résultats prédits par le modèle de H-C et des résultats obtenus par d'autres modèles pour les nanofluides (NTC/Eau) [7].

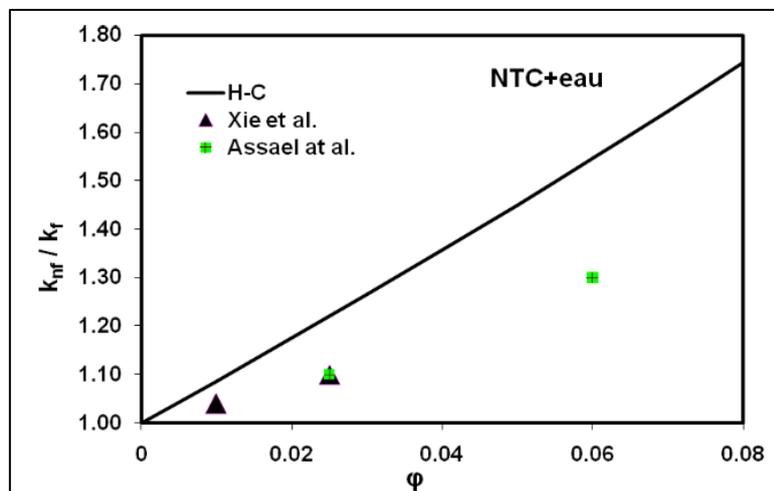


Figure I.17: Comparaison des résultats prédits par le modèle de H-C et des résultats obtenus expérimentalement pour des nanofluides (NTC/Eau) [7].

Sur la figure I.17, sont présentés les valeurs du rapport k_{nf}/k_f obtenues à partir du modèle de Hamilton-Crosser et celles obtenues des résultats expérimentaux d'Assael et al (avec ϕ entre 0% à 6%) [51] et de Xie et al (avec ϕ entre 0% et 2%) [48]. Les conductivités thermiques obtenues pour les nanofluides (NTC/Eau) sont plus grandes que celles obtenues des nanofluides avec des nanoparticules sphériques. Pour les nanofluides à base de nanotubes de carbones le modèle de Hamilton-Crosser n'estime de manière satisfaisante la conductivité thermique que pour les faibles valeurs de ϕ .

Dans le tableau I.4, sont présentées les valeurs calculées du rapport k_{nf}/k_f à partir du modèle H-C en fonction de différents $\phi\%$ pour (NTC/Eau) et (NTC/EG). On constate qu'il y a une amélioration de 54% de la conductivité thermique pour une fraction volumique de 6 % pour les deux nanofluides (NTC/Eau) et (NTC/EG). On remarque aussi que cette augmentation est quasi

linéaire avec la fraction volumique. Assael et *al.* [51] ont remarqué qu'il y a une amélioration de la conductivité thermique du nanofluide (NTC/Eau) de 28% pour une fraction volumique de 6%, alors que Choi et *al.* [74] ont trouvé une amélioration de 150% pour une fraction volumique de 1% dans les nanofluides (NTC/EG).

Table I.4: Valeurs calculées de (k_{nf}/k_f) à partir du modèle H-C en fonction de ϕ % pour deux nanofluides (NTC/Eau) et (NTC/EG) [7].

ϕ %	(k_{nf}/k_f)	
	H-C (NTC+eau)	H-C (NTC+EG)
0	1	1
1	1.0864	1.0865
2	1.1746	1.1748
3	1.2645	1.2649
4	1.3564	1.3568
5	1.4502	1.4507
6	1.5459	1.5466
7	1.6438	1.6446
8	1.7437	1.7446

Le tableau I.5 ci-dessous, montre les différentes valeurs calculées par le modèle Hamilton-Crosser du rapport (k_{nf}/k_f) en fonction de ϕ variant de 0 à 8%, et ceci pour cinq nanofluides à savoir (Al₂O₃/Eau), (CuO/Eau), (Cu/Eau), (Ag/Eau) et (Au/Eau).

Table I.5: Valeurs de (k_{nf}/k_f) calculé à partir du modèle de H-C en fonction de ϕ , pour différents nanofluides et avec l'eau comme fluide porteur.

%	Rapport des conductivités thermiques (k_{nf}/k_f)								
	0%	1%	2%	3%	4%	5%	6%	7%	8%
Al ₂ O ₃	1	1.040	1.081	1.123	1.166	1.210	1.254	1.30	1.346
CuO	1	1.038	1.077	1.116	1.157	1.198	1.239	1.282	1.326
Cu	1	1.043	1.086	1.131	1.177	1.224	1.271	1.320	1.370
Au	1	1.0429	1.0867	1.1314	1.177	1.2236	1.2712	1.3198	1.3694
Ag	1	1.0430	1.0869	1.1317	1.1774	1.2241	1.2718	1.3205	1.3702
NTC	1	1.0864	1.1746	1.2645	1.3564	1.4502	1.5459	1.6438	1.7437

I.3.2 La viscosité dynamique

La viscosité caractérise l'aptitude d'un fluide à s'écouler. La viscosité est une propriété importante de l'écoulement des fluides. Sa connaissance est fondamentale pour toutes les applications impliquant le transport de fluides, en plus le transfert de chaleur par convection dépend

directement de la viscosité des fluides. Il a été démontré précédemment que l'ajout de nanoparticules dans un fluide de base permet d'améliorer la conductivité thermique du nanofluide obtenu, mais cela peut aussi conduire à une augmentation défavorable de la viscosité dynamique [52].

La majorité des études traitant de la viscosité des nanofluides ont eu recours, pour son calcul : de la viscosité du fluide de base, de la fraction volumique ϕ et aux relations de Stokes-Einstein ou de Brinkman. Ces relations ont été établies dans des cas précis, à savoir pour des particules métalliques de forme sphérique, en faible concentration, parfaitement dispersées et sans interaction inter-particules. Or les nanoparticules utilisées dans les différentes expérimentations ne sont ni sphériques ni de même taille, en particulier lorsqu'il s'agit de nanofluides avec des nanotubes de carbone.

La dispersion de nanoparticules dans un fluide de base modifie notablement sa viscosité, il s'ensuit alors une modification de la structure des écoulements convectifs qui dépend fortement de la viscosité. Pour les suspensions constituées de nanoparticules sphériques, on dispose de différents modèles et de formules semi-empiriques décrivant l'évolution de la viscosité relative en fonction de la fraction volumique.

La viscosité relative est le rapport de la viscosité du nanofluide sur celle du fluide de base $\frac{\mu_{nf}}{\mu_f}$ [7].

1.3.2.1 Les Paramètres affectants la viscosité dynamique des nanofluides

L'ajout de particules solides dans un liquide provoque une augmentation, plus ou moins importante, de la viscosité du mélange obtenu. Là encore, de nombreux facteurs peuvent être à l'origine des disparités constatées. Pour des nanoparticules identiques (nature et taille) dans un même fluide de base ; la qualité de la dispersion, la viscosité du fluide de base, la fraction volumique des nanoparticules et la température peuvent agir considérablement sur la viscosité, comme le montre la figure I.18.



Figure I.18: Paramètres affectant la viscosité des nanofluides [72].

En augmentant la fraction volumique des nanoparticules dans un fluide porteur, on augmente sa conductivité thermique ce qui est intéressant pour le transfert de chaleur, mais cela augmente nécessairement la viscosité du nanofluide obtenu. Lorsque la viscosité dynamique augmente, la capacité du fluide à s'écouler diminue. La viscosité des liquides tend généralement à diminuer lorsque la température de ce dernier augmente. Des corrélations semi-empiriques basées sur des résultats expérimentaux sont utilisées pour le calcul de la viscosité dynamique [86, 87].

1.3.2.2 Les différents modèles de viscosités

De nombreuses études théoriques et expérimentales ont été menées afin d'estimer ou de mesurer la viscosité dynamique des nanofluides, et ceci pour quantifier l'importance d'un certain nombre de paramètres liés à la nature des nanoparticules, leur taille, la température, etc. Plusieurs modèles théoriques ont été développés pour prédire l'évolution de la viscosité dynamique des suspensions sous certaines conditions. Dans ce qui suit, nous nous intéresserons aux modèles les plus utilisés dans le cas des nanofluides [3].

a) Modèle d'Einstein

L'historique des études sur la viscosité effective des mélanges de particules-liquide est presque aussi long que celui de la conductivité thermique effective. Einstein [87] fut le premier à calculer la viscosité effective d'une suspension de sphères en se basant sur les équations hydrodynamiques. Il a déterminé l'énergie dissipée autour d'une seule particule dans un fluide en

associant son énergie au travail réalisé pour la faire avancer relativement au fluide. A partir de ce résultat, il a trouvé une expression décrivant une dépendance linéaire de la viscosité des suspensions dans un fluide avec leur concentration :

$$\mu_{nf} = \mu_f(1 + 2.5\varphi) \quad (\text{I.21})$$

Où μ_{nf} et μ_f dénotent respectivement la viscosité du nanofluide et la viscosité du fluide de base. φ est la fraction volumique des nanoparticules.

La formule d'Einstein a depuis été vérifiée expérimentalement et est considérée satisfaisante pour des suspensions très diluées de petites particules sphériques (Browniennes ou non Browniennes). Cette relation n'est valable que pour des concentrations volumiques inférieures à 1%. Il est à noter que ce modèle ne tient pas compte des effets de la taille des particules et des interactions inter-particules [3,7].

b) Modèle de Brinkman

La formule de Brinkman [89] complète le modèle d'Einstein jusqu'à une concentration volumique inférieure à 4%, et elle est favorablement acceptée par de nombreux chercheurs.

$$\mu_{nf} = \frac{\mu_f}{(1-\varphi)^{2.5}} \quad (\text{I.22})$$

La formule de Brinkman décrit une évolution non linéaire de la viscosité dynamique avec la concentration volumique mais ne tient pas compte de la collision entre les particules [3, 52, 7].

c) Modèle de Batchelor

En prenant en compte l'effet du mouvement Brownien et en considérant une suspension isotrope de nanoparticules solides et sphériques, Batchelor [90] a développé l'équation de viscosité d'Einstein. Il a montré aussi que la viscosité n'est pas une fonction linéaire de φ , mais une fonction non linéaire de φ avec la présence d'un terme en φ^2 .

Son modèle est donné par :

$$\mu_{nf} = \mu_f(1 + \eta\varphi + k_H \varphi^2) \quad (\text{I.23})$$

Où η est la viscosité intrinsèque et k_H est le coefficient de Huggins. La valeur de η et k_H est de 2.5 et 6.5 respectivement pour des particules sphériques. Cette équation permet le calcul de la viscosité de suspension de nanoparticules avec $\varphi > 10\%$ [3, 52, 7].

d) Modèle Maiga et al

D'autres relations ont été proposées dans la littérature qui se limite à des applications bien précises. Maiga et al. [18] ont proposé une corrélation à partir de résultats de mesures, à savoir :

$$\mu_{nf} = \mu_f(123\varphi^2 + 7.3\varphi + 1) \quad (\text{I.24})$$

En comparant cette corrélation aux modèles d'Einstein et de Brinkman, on trouve que ces deux dernières approches sous-estiment les valeurs expérimentales de la viscosité des nanofluides.

e) Modèle Pack et Cho

Pack et Cho [40] ont développé un modèle de calcul de la viscosité des nanofluides basé sur la fraction volumique des nanoparticules Al_2O_3 disperses dans l'eau en prenant la température ambiante comme référence. Ils ont constaté que la viscosité du nanofluide diminue lorsque la température augmente. Ce modèle est donné par :

$$\mu_{nf} = \mu_f(533.9\varphi^2 + 39.11\varphi + 1) \quad (\text{I.15}) \quad (\text{I.25})$$

I.3.2.3 Viscosité dynamique des nanofluides

La compréhension des problèmes de convection est strictement liée à la viscosité des nanofluides [2]. Et les données expérimentales de la viscosité effective sont limitées à certains nanofluides, tels que :

- $\text{Al}_2\text{O}_3/\text{Eau}$; (Pak et Cho [40], Das et al. [36], Putra et al. [91], Li et al. [92], Heris et al. [93]).
- CuO/Eau ; (Heris et al [93], Kulkarni et al. [94]).
- TiO_2/Eau ; (Pak et Cho [40]).
- MWCNT/Eau ; (Ding et al. [50]).
- $\text{Al}_2\text{O}_3/\text{Octane}$; (Liu et al. [66]).

Afin de minimiser la divergence entre les mesures expérimentales et les calculs, les chercheurs ont proposé des équations pour des applications spécifiques telle que : $\text{Al}_2\text{O}_3/\text{Eau}$ et $\text{Al}_2\text{O}_3/\text{Ethylène glycol}$ (Maïga et al. [18]), TiO_2/Eau (Tseng et Lin [95]) et CuO/Eau (Kulkarni et al. [38]). Le problème avec ces équations, c'est qu'elles ne se réduisent pas à l'équation d'Einstein pour de très faibles concentrations volumique, et par conséquent elles manquent de base physique. Nguyen et al. [96] ont montré que la viscosité augmente avec la concentration de particules et décroît avec la température. Ils ont remarqué aussi que pour une fraction volumique de particules inférieure à 4%, la taille n'a quasiment pas d'influence sur la viscosité. Alors que pour des fractions supérieures, la taille des particules joue un rôle important. Prasher et al. [38] ont aussi étudié l'influence de la taille des particules sur la viscosité dynamique pour différents nanofluides et à des concentrations identiques ; et selon les courbes obtenues rien ne permet de tirer de conclusions probantes [71].

Pak et Cho [40] se sont également penchés sur la variation de la viscosité de deux nanofluides et ont montré que leur comportement ne peut se prédire par des modèles empiriques standards pour les viscosités de suspension, comme celui développé par Das et al. [97]. Lee et al. [35] ont rapporté une augmentation substantielle de la viscosité pour l'eau et les nanofluides à base d'éthylène glycol pour les nanoparticules d' Al_2O_3 . Ils ont également évoqué que cette augmentation pourrait compenser le transfert de chaleur observé dans les nanofluides [2].

Das et *al.* [36] ont mené une étude similaire pour un nanofluide $\text{Al}_2\text{O}_3/\text{Eau}$, ils ont confirmé en particulier, le comportement Newtonien du nanofluide pour des concentrations de 1% à 4%. Ils ont également montré une tendance linéaire de la viscosité par rapport au taux de cisaillement, même si les valeurs de viscosité sont encore plus élevées que celles de l'eau pure [2].

Il existe des divergences dans la littérature sur la nature de la rhéologie des nanofluides ; certains auteurs croient que les nanofluides sont Newtoniens [34, 38] alors que d'autres ont vu que les nanofluides sont non Newtoniens [50]. Dans ce contexte, Chen et *al.* [81] ont réalisé des études à la fois expérimentales et théoriques de l'éthylène-glycol avec des nanoparticules de TiO_2 , pour des concentrations de 0,5% à 8,0% en poids et à une gamme de température variant de 20 à 60 °C. Leurs résultats ont montré que dans ces conditions le comportement du nanofluide est Newtonien [2].

Sergis et Hardalupas [98] ont également conduit des analyses statistiques de convection de chaleur des nanofluides ; et ils ont trouvé que le mode de convection semble être augmenté avec l'augmentation de la température, de la concentration volumétrique des nanoparticules et de la dimension décroissante des particules. Malheureusement, les expériences sur la convection couvrent seulement des nanoparticules d'oxyde avec des concentrations élevées de nanoparticule ($> 1\%$ du volume). En plus, les expériences de convection sont aussi nécessaires pour pallier à ces lacunes, particulièrement de particules métalliques (qui ont une conductivité thermique beaucoup plus élevée) et pour de faibles concentrations ($< 1\%$ du volume) [99].

I.3.3 La masse volumique

La masse volumique d'une substance, notée ρ , correspond à la masse de cette substance dans une unité de volume. La masse volumique des nanofluides est proportionnelle à la fraction volumique des particules solides. Le calcul de la masse volumique effective ρ_{nf} d'un nanofluide est assez simple et assez conforme aux valeurs expérimentales. Elle est souvent estimée sur la base du principe de la règle de mélange en supposant le nanofluide comme un milieu homogène (bonne dispersion des nanoparticules dans le fluide) [40, 100].

La masse volumique du nanofluide est donnée par la formule suivante :

$$\rho_{nf} = (1 - \varphi)\rho_f + \varphi\rho_p \quad (\text{I.26})$$

Où ρ_{nf} , ρ_p et ρ_f dénotent respectivement la masse volumique du nanofluide, la masse volumique des nanoparticules et la masse volumique du fluide de base.

Les valeurs des rapports de la masse volumique des nanofluides sur la masse volumique du fluide de base pour cinq nanofluides ($\text{eau}+\text{Al}_2\text{O}_3$), ($\text{eau}+\text{CuO}$), ($\text{eau}+\text{Cu}$), ($\text{eau}+\text{Ag}$) et ($\text{eau}+\text{Au}$) en fonction de la fraction volumique (φ) qui varie entre 0% et 8% ; sont présentées dans le tableau I.6.

Table I.6: Rapport de masses volumiques des différents nanofluides en fonction de la fraction volumique [7]

$\varphi\%$	ρ_{nf}/ρ_f				
	Al_2O_3/Eau	CuO/Eau	Cu/Eau	Ag/Eau	Au/Eau
0%	1	1	1	1	1
1%	1.0296	1.0546	1.0797	1.0951	1.1833
2%	1.0593	1.1092	1.1594	1.1903	1.3666
3%	1.0890	1.1638	1.2391	1.2855	1.5500
4%	1.1186	1.2184	1.3188	1.3807	1.7333
5%	1.1483	1.2730	1.3985	1.4759	1.9167
6%	1.1780	1.3276	1.4782	1.5711	2.1000
7%	1.2077	1.3823	1.5579	1.6663	2.2834
8%	1.2373	1.4369	1.6376	1.7615	2.4667

I.3.4 La chaleur spécifique

La chaleur spécifique C_p est la capacité calorifique par unité de masse d'une substance ou d'un système homogène. La chaleur spécifique correspond à l'apport de chaleur nécessaire pour élever la température de l'unité de substance de 1K lors de la transformation considérée. Elle reflète la capacité d'un matériau à accumuler de l'énergie sous forme thermique, pour une masse donnée, quand sa température croît. Une capacité thermique élevée signifie qu'une grande quantité d'énergie peut être stockée moyennant une augmentation relativement faible de la température. La dispersion de nanoparticules solides aux fluides de base provoque généralement une diminution de la chaleur spécifique du nanofluide obtenu, car la chaleur spécifique des nanoparticules solides est plus faible que celle des fluides de base [3, 52].

Il existe deux modèles pour le calcul de la chaleur spécifique des nanofluides. La chaleur spécifique peut être estimée à l'aide de la règle des mélanges ou sur la base de l'hypothèse de l'équilibre thermique neutre des particules solides et du fluide de base.

En se basant sur la règle de mélange d'une suspension homogène, Pak et Cho [40] ont proposé l'expression suivante pour le calcul de la chaleur spécifique de nanofluides :

$$C_{p\,eff} = \varphi C_{p\,p} + (1 - \varphi) C_{p\,fb} \quad (I.27)$$

Où $C_{p\,eff}$, $C_{p\,p}$ et $C_{p\,fb}$ dénotent respectivement la chaleur spécifique du nanofluide, la chaleur spécifique des nanoparticules et la chaleur spécifique du fluide de base. Et φ est la fraction volumique des nanoparticules.

De son côté, Xuan et Roetzel [101] ont développé un modèle de la chaleur spécifique des nanofluides basé sur l'hypothèse de l'équilibre thermique entre les particules solides et le fluide de base de la manière suivante :

$$C_{p\text{ eff}} = \frac{\varphi\rho_p C_{p p} + (1-\varphi)\rho_{fb} C_{p fb}}{\varphi\rho_p + (1-\varphi)\rho_{fb}} \quad (\text{I.28})$$

Où ρ_p, ρ_{fb} dénotent respectivement la masse volumique des nanoparticules et la masse volumique du fluide de base.

Cette expression a été jugée mieux adaptée pour le calcul de la chaleur spécifique des nanofluides par certains chercheurs [52].

I.3.5 Coefficient d'expansion thermique

La variation de masse volumique sous l'action de la température est caractérisée par le coefficient d'expansion thermique $\beta_T = -\frac{1}{\rho} \left(\frac{\partial \rho}{\partial T} \right)_p$ appelé également coefficient de dilatabilité.

Pour calculer la valeur de ce coefficient pour les nanofluides de très nombreux auteurs ont proposé par analogie avec la relation [7, 52]:

$$\rho_{nf} = (1 - \varphi)\rho_f + \varphi\rho_p \quad (\text{I.29})$$

L'expression suivante :

$$\beta_{nf} = (1 - \varphi)\beta_f + \varphi\beta_p \quad (\text{I.30})$$

Où β_f et β_p désignent respectivement les coefficients de dilatabilité du fluide porteur et celle des nanoparticules.

I.4 Conclusion

Dans ce chapitre, nous avons d'abord donné une description générale des nanofluides (synthèse, caractérisation, production et applications). Une revue bibliographique détaillée de leurs propriétés thermophysiques et de leurs performances thermiques et hydrodynamiques a ensuite été abordée. Ainsi, nous avons montré à travers cette analyse que les performances des nanofluides dépendent fortement de nombreux paramètres tels que la structure et la qualité des nanoparticules ainsi que le type du fluide de base.

Par conséquent, il est nécessaire d'évaluer rigoureusement les propriétés thermophysiques des nanofluides afin de mieux comprendre leur comportement d'écoulement et leurs propriétés thermiques en vue d'une éventuelle application dans les systèmes thermiques.

D'après cette étude bibliographique, il est difficile de comparer les différents résultats expérimentaux des nanofluides car chaque expérience a été menée pour des nanoparticules de différentes tailles et avec de préparations d'échantillons distinctes. Or la taille des particules et la préparation des échantillons sont des facteurs déterminants qui influent fortement sur les résultats obtenus. En plus L'agglomération des particules ne nous permet pas d'étudier de manière rigoureuse l'influence de la taille de ces dernières sur l'augmentation de conductivité thermique du fluide.

D'autres approches théoriques ont tenté de comprendre l'origine et l'importance de cette augmentation de la conductivité thermique des nanofluides. Néanmoins aucune d'entre elles n'est parvenue à décrire convenablement tous les comportements obtenus expérimentalement.

Un meilleur contrôle des propriétés physico chimiques de ces fluides serait donc nécessaire pour pouvoir les étudier de façon précise et ainsi comprendre leur comportement.

I.5 Références

- [1] Choi, S. U., Eastman, J. A. (1995). Enhancing thermal conductivity of fluids with nanoparticles. ASME Fluid Eng. Division, 231, 99-105.
- [2] BOUDAUD, W. (2019). Simulation numérique de la convection naturelle dans des cavités remplies des nanofluides, USTO MB, Oran, Mars.
- [3] KHENTOUL, M. (2016). Étude Numérique de la Convection Mixte dans un Canal Horizontal Contenant des Ailettes. Doctoral dissertation, Frères Mentouri – Constantine. Algeria.
- [4] Ophélie, Z. (2008). Etudes des interactions physicochimiques et biologiques entre des nanoparticules manufacturées et des bactéries de l'environnement, Doctoral dissertation, Paris VI - Pierre et Marie Curie.
- [5] HAMZE, S. (2020). Graphene based nanofluids: development, characterization and application for heat and energy systems, Doctoral thesis, Rennes 1, France.
- [6] TAHIRI, A. (2017). Contribution à l'étude des transferts thermo convectifs d'un fluide non Newtonien en écoulement dans un conduit, Doctoral dissertation, UMBB BOUMERDES, Algeria.
- [7] Gladés, B. (2010). Contribution à l'étude de la convection naturelle dans les nanofluides en configuration de Rayleigh-Bénard, Doctoral dissertation, Toulouse III- Paul Sabatier, France.
- [8] Eastman, J. A., Choi, U. S., Li, S., Thompson, L. J., Lee, S. (1996). Enhanced thermal conductivity through the development of nanofluids, Argonne National Lab ANL/MSD/CP-90462.
- [9] Okonkwo, E. C., Wole-Osho, I., Almanassra, I. W., Abdullatif, Y. M., Al-Ansari, T. (2020). An updated review of nanofluids in various heat transfer devices. Journal of Thermal Analysis and Calorimetry, 142, 1-56.

- [10] SEZER, Ö. S., Yazıcıođ, A. G., Kakac, S. (2010). Convective heat transfer enhancement with nanofluids: the effect of temperature-variable thermal conductivity. In *Engineering Systems Design and Analysis*, 49163, 719-731.
- [11] Castellanos, J. B. (2014). Thermal conductivity of alumina and silica nanofluids. Diss. Minnesota State University, Mankato.
- [12] Choi, S. U. S., Zhang, Z. G., Yu, W., Lockwood, F. E., Grulke, E. A. (2001). Anomalous thermal conductivity enhancement in nanotube suspensions. *Applied physics letters*, 79(14), 2252-2254.
- [13] J Eastman, J. A., Choi, S. U. S., Li, S., Yu, W., & Thompson, L. J. (2001). Anomalously increased effective thermal conductivities of ethylene glycol-based nanofluids containing copper nanoparticles. *Applied physics letters*, 78(6), 718-720.
- [14] Koblinski, P., Eastman, J. A., Cahill, D. G. (2005). Nanofluids for thermal transport. *Materials today*, 8(6), 36-44.
- [15] Yang, Y., Zhang, Z. G., Grulke, E. A., Anderson, W. B., Wu, G. (2005). Heat transfer properties of nanoparticle-in-fluid dispersions (nanofluids) in laminar flow. *International journal of heat and mass transfer*, 48(6), 1107-1116.
- [16] Daungthongsuk, W., Wongwises, S. (2007). A critical review of convective heat transfer of nanofluids. *Renewable and sustainable energy reviews*, 11(5), 797-817.
- [17] Vadasz, P. (2006). Heat conduction in nanofluid suspensions, 128, 465-477.
- [18] Maiga, S. E. B., Palm, S. J., Nguyen, C. T., Roy, G., Galanis, N. (2005). Heat transfer enhancement by using nanofluids in forced convection flows. *International journal of heat and fluid flow*, 26(4), 530-546.
- [19] Namburu, P. K., Kulkarni, D. P., Misra, D., Das, D. K. (2007). Viscosity of copper oxide nanoparticles dispersed in ethylene glycol and water mixture. *Experimental Thermal and Fluid Science*, 32(2), 397-402.
- [20] Behzadmehr, A., Saffar-Avval, M., Galanis, N. (2007). Prediction of turbulent forced convection of a nanofluid in a tube with uniform heat flux using a two phase approach. *International Journal of Heat and Fluid Flow*, 28(2), 211-219.
- [21] Mirmasoumi, S., Behzadmehr, A. (2008). Numerical study of laminar mixed convection of a nanofluid in a horizontal tube using two-phase mixture model. *Applied Thermal Engineering*, 28(7), 717-727.
- [22] Menni, Y., Chamkha, A. J., Lorenzini, G., Kaid, N., Ameer, H., Bensafi, M. (2019). Advances of nanofluids in solar collectors—a review of numerical studies advances of nanofluids in solar collectors—a review of numerical studies. *Math Model Eng Probl*, 6(3), 415-427.
- [23] Wahab, A., Hassan, A., Qasim, M. A., Ali, H. M., Babar, H., Sajid, M. U. (2019). Solar energy systems—potential of nanofluids. *Journal of Molecular Liquids*, 289, 111049.
- [24] Ibrahim, H., Sazali, N., Shah, A. S. M., Karim, M. S. A., Aziz, F., Salleh, W. N. W. (2019). A review on factors affecting heat transfer efficiency of nanofluids for application in plate heat exchanger. *Journal of Advanced Research in Fluid Mechanics and Thermal Sciences*, 60(1), 144-154.

- [25] Sajid, M. U., Ali, H. M. (2019). Recent advances in application of nanofluids in heat transfer devices: a critical review. *Renewable and Sustainable Energy Reviews*, 103, 556-592.
- [26] Nazari, M. A., Ahmadi, M. H., Sadeghzadeh, M., Shafii, M. B., Goodarzi, M. (2019). A review on application of nanofluid in various types of heat pipes. *Journal of Central South University*, 26(5), 1021-1041.
- [27] Vele, N. S., Patil, R. K. (2019). Review on heat transfer enhancement in car radiator using Nano fluids. In: *Proceedings of the International Conference on Industrial Engineering and Operations Management*. Bangkok, Thailand, March 5-7, pp. 527–537.
- [28] Krishna, V. M., Kumar, M. S., Mahesh, O., Kumar, P. S. (2021). Numerical investigation of heat transfer and pressure drop for cooling of microchannel heat sink using MWCNT-CuO-Water hybrid nanofluid with different mixture ratio. *Materials Today: Proceedings*, 17:295-302.
- [29] Ramezanizadeh, M., Nazari, M. A., Ahmadi, M. H., Lorenzini, G., Pop, I. (2019). A review on the applications of intelligence methods in predicting thermal conductivity of nanofluids. *Journal of Thermal Analysis and Calorimetry*, 138(1), 827-843.
- [30] Sezer, N., Atieh, M. A., Koç, M. (2019). A comprehensive review on synthesis, stability, thermophysical properties, and characterization of nanofluids. *Powder technology*, 344, 404-431.
- [31] Murshed, S. M., Sharifpur, M., Giwa, S., & Meyer, J. P. (2020). Experimental Research and Development on the Natural Convection of Suspensions of Nanoparticles-A Comprehensive Review. *Nanomaterials*, 10(9), 1855.
- [32] Maxwell J.C. 1881. *A treatise on electricity and magnetism*, Clarendon Press, Oxford, UK, Second Edition.
- [33] Masuda, H., Ebata, A., Teramae, K. (1993). Alteration of thermal conductivity and viscosity of liquid by dispersing ultra-fine particles. Dispersion of Al₂O₃, SiO₂ and TiO₂ ultra-fine particles.
- [34] Wang, X., Xu, X., Choi, S. U. (1999). Thermal conductivity of nanoparticle-fluid mixture. *Journal of thermophysics and heat transfer*, 13(4), 474-480.
- [35] Lee, S., Choi, S. S., Li, S. A., Eastman, J. A. (1999). Measuring thermal conductivity of fluids containing oxide nanoparticles.
- [36] Das, S. K., Putra, N., Thiesen, P., Roetzel, W. (2003). Temperature dependence of thermal conductivity enhancement for nanofluids. *J. Heat Transfer*, 125(4), 567-574.
- [37] Xie, H., Wang, J., Xi, T., Liu, Y., Ai, F., Wu, Q. (2002). Thermal conductivity enhancement of suspensions containing nanosized alumina particles. *Journal of applied physics*, 91(7), 4568-4572.
- [38] Prasher, R., Phelan, P. E., Bhattacharya, P. (2006). Effect of aggregation kinetics on the thermal conductivity of nanoscale colloidal solutions (nanofluid). *Nano letters*, 6(7), 1529-1534.
- [39] Li, C. H., Peterson, G. P. (2006). Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids). *Journal of Applied Physics*, 99(8), 084314.

- [40] Pak, B. C., Cho, Y. I. (1998). Hydrodynamic and heat transfer study of dispersed fluids with submicron metallic oxide particles. *Experimental Heat Transfer an International Journal*, 11(2), 151-170.
- [41] Murshed, S. M. S., Leong, K. C., Yang, C. (2006). Thermal conductivity of nanoparticle suspensions (nanofluids). In: *Proceeding IEEE conference on emerging technologies-nanoelectronics*, IEEE, Singapore, January 10-13, 155-158. 10.1109/NANOEL.2006.1609703
- [42] Xuan, Y., Li, Q. (2000). Heat transfer enhancement of nanofluids. *International Journal of heat and fluid flow*, 21(1), 58-64.
- [43] Patel, H. E., Das, S. K., Sundararajan, T., Sreekumaran Nair, A., George, B., Pradeep, T. (2003). Thermal conductivities of naked and monolayer protected metal nanoparticle based nanofluids: Manifestation of anomalous enhancement and chemical effects. *Applied Physics Letters*, 83(14), 2931-2933.
- [44] Kumar, D. H., Patel, H. E., Kumar, V. R., Sundararajan, T., Pradeep, T., Das, S. K. (2004). Model for heat conduction in nanofluids. *Physical Review Letters*, 93(14), 144301.
- [45] Berber, S., Kwon, Y. K., Tománek, D. (2000). Unusually high thermal conductivity of carbon nanotubes. *Physical review letters*, 84(20), 4613.
- [46] Shenogin, S., Bodapati, A., Xue, L., Ozisik, R., Koblinski, P. (2004). Effect of chemical functionalization on thermal transport of carbon nanotube composites. *Applied Physics Letters*, 85(12), 2229-2231.
- [47] Wang, Y., Iqbal, Z., Mitra, S. (2006). Rapidly functionalized, water-dispersed carbon nanotubes at high concentration. *Journal of the American Chemical Society*, 128(1), 95-99.
- [48] Xie, H., Lee, H., Youn, W., Choi, M. (2003). Nanofluids containing multiwalled carbon nanotubes and their enhanced thermal conductivities. *Journal of Applied physics*, 94(8), 4967-4971.
- [49] Wen, D., Ding, Y. (2004). Effective thermal conductivity of aqueous suspensions of carbon nanotubes (carbon nanotube nanofluids). *Journal of thermophysics and heat transfer*, 18(4), 481-485.
- [50] Ding, Y., Alias, H., Wen, D., Williams, R. A. (2006). Heat transfer of aqueous suspensions of carbon nanotubes (CNT nanofluids). *International Journal of Heat and Mass Transfer*, 49(1-2), 240-250.
- [51] Assael, M. J., Chen, C. F., Metaxa, I., Wakeham, W. A. (2004). Thermal conductivity of suspensions of carbon nanotubes in water. *International Journal of Thermophysics*, 25(4), 971-985.
- [52] ZOHUD, M. K. A. (2018). Amélioration des caractéristiques thermiques des réfrigérants par l'addition de nanoparticules, Doctoral dissertation, Université Mohamed Boudiaf des Sciences et de la Technologie-Mohamed Boudiaf d'Oran. Algeria.
- [53] Tzeng, S. C., Lin, C. W., Huang, K. D. (2005). Heat transfer enhancement of nanofluids in rotary blade coupling of four-wheel-drive vehicles. *Acta Mechanica*, 179(1), 11-23.
- [54] Akhavan-Behabadi, M. A., Sadoughi, M. K., Darzi, M., Fakoor-Pakdaman, M. (2015). Experimental study on heat transfer characteristics of R600a/POE/CuO nano-refrigerant flow condensation. *Experimental Thermal and Fluid Science*, 66, 46-52.

- [55] Yang, D., Sun, B., Li, H., Fan, X. (2015). Experimental study on the heat transfer and flow characteristics of nanorefrigerants inside a corrugated tube. *International Journal of Refrigeration*, 56, 213-223.
- [56] Darzi, M., Sadoughi, M. K., Sheikholeslami, M. (2018). Condensation of nano-refrigerant inside a horizontal tube. *Physica B: Condensed Matter*, 537, 33-39.
- [57] Tsai, C. Y., Chien, H. T., Ding, P. P., Chan, B., Luh, T. Y., Chen, P. H. (2004). Effect of structural character of gold nanoparticles in nanofluid on heat pipe thermal performance. *Materials Letters*, 58(9), 1461-1465.
- [58] Ma, H. B., Wilson, C., Borgmeyer, B., Park, K., Yu, Q., Choi, S. U. S., Tirumala, M. (2006). Effect of nanofluid on the heat transport capability in an oscillating heat pipe. *Applied Physics Letters*, 88(14), 143116.
- [59] You, S. M., Kim, J. H., Kim, K. H. (2003). Effect of nanoparticles on critical heat flux of water in pool boiling heat transfer. *Applied physics letters*, 83(16), 3374-3376.
- [60] Vassallo, P., Kumar, R., D'Amico, S. (2004). Pool boiling heat transfer experiments in silica-water nano-fluids. *International Journal of Heat and Mass Transfer*, 47(2), 407-411.
- [61] Jordan, A., Scholz, R., Wust, P., Föhling, H., Felix, R. (1999). Magnetic fluid hyperthermia (MFH): Cancer treatment with AC magnetic field induced excitation of biocompatible superparamagnetic nanoparticles. *Journal of Magnetism and Magnetic materials*, 201(1-3), 413-419.
- [62] Elsheikh, A. H., Sharshir, S. W., Mostafa, M. E., Essa, F. A., Ali, M. K. A. (2018). Applications of nanofluids in solar energy: a review of recent advances. *Renewable and Sustainable Energy Reviews*, 82, 3483-3502.
- [63] Phuoc, T. X., Massoudi, M., Chen, R. H. (2011). Viscosity and thermal conductivity of nanofluids containing multi-walled carbon nanotubes stabilized by chitosan. *International Journal of Thermal Sciences*, 50(1), 12-18.
- [64] Beck, M. P., Yuan, Y., Warriar, P., Teja, A. S. (2009). The effect of particle size on the thermal conductivity of alumina nanofluids. *Journal of Nanoparticle research*, 11(5), 1129-1136.
- [65] Choi, S. U. S., Zhang, Z. G., Yu, W., Lockwood, F. E., Grulke, E. A. (2001). Anomalous thermal conductivity enhancement in nanotube suspensions. *Applied physics letters*, 79(14), 2252-2254.
- [66] Liu, M. S., Lin, M. C. C., Tsai, C. Y., Wang, C. C. (2006). Enhancement of thermal conductivity with Cu for nanofluids using chemical reduction method. *International Journal of Heat and Mass Transfer*, 49(17-18), 3028-3033.
- [67] Özerinç, S., Kakaç, S., Yazıcıoğlu, A. G. (2010). Enhanced thermal conductivity of nanofluids: a state-of-the-art review. *Microfluidics and Nanofluidics*, 8(2), 145-170.
- [68] Putnam, S. A., Cahill, D. G. (2004). Micron-scale apparatus for measurements of thermodiffusion in liquids. *Review of scientific instruments*, 75(7), 2368-2372.

- [69] Wang, Z. (2009). Thermal wave in thermal properties measurements and flow diagnostics: With applications of nanofluids thermal conductivity and wall shear stress measurements. Doctoral dissertation, Oregon State University, Corvallis, OR.
- [70] Buongiorno, J., Venerus, D. C., Prabhat, N., McKrell, T., Townsend, J., Christianson, R., ... Zhou, S. Q. (2009). A benchmark study on the thermal conductivity of nanofluids. *Journal of Applied Physics*, 106(9), 094312.
- [71] Mammeri, A. (2014). Amélioration des performances énergétiques des systèmes de refroidissement industriels : Application aux serveurs informatiques, Doctoral dissertation, Paris, ENSAM.
- [72] Arshad, A., Jabbar, M., Yan, Y., Reay, D. (2019). A review on graphene based nanofluids: Preparation, characterization and applications. *Journal of Molecular Liquids*, 279, 444-484.
- [73] Subramanian, K. R. V., Rao, T. N., Balakrishnan, A. (2019). *Nanofluids and their engineering applications*. CRC Press.
- [74] Hamilton, R. L., Crosser, O. K. (1962). Thermal conductivity of heterogeneous two-component systems. *Industrial & Engineering chemistry fundamentals*, 1(3), 187-191.
- [75] Yu, W., Choi, S. U. S. (2003). The role of interfacial layers in the enhanced thermal conductivity of nanofluids: a renovated Maxwell model. *Journal of nanoparticle research*, 5(1), 167-171.
- [76] Bruggeman, V. D. (1935). Berechnung verschiedener physikalischer Konstanten von heterogenen Substanzen. I. Dielektrizitätskonstanten und Leitfähigkeiten der Mischkörper aus isotropen Substanzen. *Annalen der physik*, 416(7), 636-664.
- [77] Hasselman, D. P. H., Johnson, L. F. (1987). Effective thermal conductivity of composites with interfacial thermal barrier resistance. *Journal of composite materials*, 21(6), 508-515.
- [78] Jang, S. P., Choi, S. U. (2004). Role of Brownian motion in the enhanced thermal conductivity of nanofluids. *Applied physics letters*, 84(21), 4316-4318.
- [79] Koo, J., Kleinstreuer, C. (2004). A new thermal conductivity model for nanofluids. *Journal of Nanoparticle research*, 6(6), 577-588.
- [80] Xuan, Y., Li, Q., Hu, W. (2003). Aggregation structure and thermal conductivity of nanofluids. *AIChE Journal*, 49(4), 1038-1043.
- [81] Chen, H., Ding, Y., He, Y., Tan, C. (2007). Rheological behaviour of ethylene glycol based titania nanofluids. *Chemical physics letters*, 444(4-6), 333-337.
- [82] Nan, C. W., Liu, G., Lin, Y., Li, M. (2004). Interface effect on thermal conductivity of carbon nanotube composites. *Applied Physics Letters*, 85(16), 3549-3551.
- [83] Fricke, H. (1924). A mathematical treatment of the electric conductivity and capacity of disperse systems I. The electric conductivity of a suspension of homogeneous spheroids. *Physical Review*, 24(5), 575.
- [84] Fricke, H. (1953). The Maxwell-Wagner dispersion in a suspension of ellipsoids. *The Journal of Physical Chemistry*, 57(9), 934-937.

- [85] Nan, C. W., Shi, Z., Lin, Y. (2003). A simple model for thermal conductivity of carbon nanotube-based composites. *Chemical Physics Letters*, 375(5-6), 666-669.
- [86] K.D. Hagen. *Heat transfer with applications*. Prentice-hall, New Jersey, USA, 637-638, 1999.
- [87] Nguyen, C.T., Desgranges, F., Roy, G., Galanis, N., Mare, T., Boucher, S., Mints. H.A. (2007). Mesure de viscosité Al_2O_3 -eau, phénomène d'hystérésis, Colloque Interuniversitaire Franco-québécois, Montréal, Canada).
- [88] A. Einstein. *Investigations on the Theory of the Brownian Movement*. Dover Publications, New York, 1956.
- [89] Brinkman, H. C. (1952). The viscosity of concentrated suspensions and solutions. *The Journal of Chemical Physics*, 20(4), 571-571.
- [90] Batchelor, G. (1976). Brownian diffusion of particles with hydrodynamic interaction. *Journal of Fluid Mechanics*, 74(1), 1-29.
- [91] Putra, N., Roetzel, W., Das, S. K. (2003). Natural convection of nano-fluids. *Heat and mass transfer*, 39(8), 775-784.
- [92] Li, C., Akinc, M., Wiench, J., Pruski, M., Schilling, C. H. (2005). Relationship between water mobility and viscosity of nanometric alumina suspensions. *Journal of the American Ceramic Society*, 88(10), 2762-2768.
- [93] Heris, S. Z., Etemad, S. G., Esfahany, M. N. (2006). Experimental investigation of oxide nanofluids laminar flow convective heat transfer. *International communications in heat and mass transfer*, 33(4), 529-535.
- [94] Kulkarni, D. P., Das, D. K., Chukwu, G. A. (2006). Temperature dependent rheological property of copper oxide nanoparticles suspension (nanofluid). *Journal of nanoscience and nanotechnology*, 6(4), 1150-1154.
- [95] Tseng, W. J., Lin, K. C. (2003). Rheology and colloidal structure of aqueous TiO_2 nanoparticle suspensions. *Materials science and engineering: A*, 355(1-2), 186-192.
- [96] Nguyen, C. T., Desgranges, F., Galanis, N., Roy, G., Maré, T., Boucher, S., Mints, H. A. (2008). Viscosity data for Al_2O_3 -water nanofluid—hysteresis: is heat transfer enhancement using nanofluids reliable? ; *International journal of thermal sciences*, 47(2), 103-111.
- [97] Das, SK. Choi, S U S. Yu, W. Pradeep, T. *Nanofluids: Science and Technology*. Hoboken, NJ: John Wiley & Sons, 2007.
- [98] Sergis, A., Hardalupas, Y. (2011). Anomalous heat transfer modes of nanofluids: a review based on statistical analysis. *Nanoscale research letters*, 6(1), 1-37.
- [99] Saidur, R., Leong, K. Y., & Mohammed, H. A. (2011). A review on applications and challenges of nanofluids. *Renewable and sustainable energy reviews*, 15(3), 1646-1668.

- [100] Ferrouillat, S., Bontemps, A., Ribeiro, J. P., Gruss, J. A., Soriano, O. (2011). Hydraulic and heat transfer study of SiO₂/water nanofluids in horizontal tubes with imposed wall temperature boundary conditions. *International journal of heat and fluid flow*, 32(2), 424-439.
- [101] Xuan, Y., Roetzel, W. (2000). Conceptions for heat transfer correlation of nanofluids. *International Journal of heat and Mass transfer*, 43(19), 3701-3707.

The background features three large, vibrant green circles of varying sizes. One is at the top center, a smaller one is below it to the right, and a large one is at the bottom right. Two thin green lines intersect: one runs diagonally from the top left towards the center, and another runs from the top right towards the bottom right. The text 'Chapitre II' is centered in a green, italicized serif font.

Chapitre II

Introduction

L'expérimentateur, quel que soit son domaine d'étude, est toujours confronté au problème difficile de l'organisation optimale de ses essais. C'est-à-dire comment obtenir les bonnes informations dans les meilleurs délais et pour le moindre coût.

Les scientifiques ont proposé différentes méthodes qui permettent l'optimisation du choix des essais et de celui de leur enchaînement en cours de l'expérimentation. Celles-ci sont plus efficaces que les démarches habituelles de conduite des essais, permettant ainsi d'arriver aux mêmes résultats qu'avec trois à quatre fois moins d'essais.

Ce chapitre examine l'approche mathématique et la modélisation des transferts de chaleur de nanofluides dans le but de développer un nouveau modèle mathématique de la conductivité thermique des nanofluides en incluant les paramètres les plus influents. Ce modèle est généré par la méthode des plans d'expérience présentée dans la première partie de ce chapitre.

En ce qui concerne la deuxième partie, elle présente la technique des Réseaux de Neurones Artificiels (RNA). Celle-ci est une technique de traitement de données, ayant des fonctionnalités d'identification, de contrôle ou de filtrage aboutissant à des solutions plus efficaces.

L'objectif de ce chapitre est de préciser les notions qui permettent d'évaluer et d'améliorer l'aptitude du modèle postulé à représenter les résultats expérimentaux. En un mot, ces notions nous aideront à trouver le modèle adéquat, qui représente le mieux possible les données expérimentales et qui devrait nous permettre de faire des prévisions de qualité.

II.1 Théorie des plans d'expériences

II.1.1 Introduction

La théorie des plans d'expériences optimaux est une branche importante des statistiques, à l'interface avec l'optimisation, qui a de nombreux champs d'applications. Son but est de trouver les valeurs qu'un expérimentateur doit donner aux variables de contrôle des expériences à sa disposition, avant de les réaliser. Ces variables de contrôle peuvent prendre différentes formes (nombre de fois qu'on va réaliser une expérience, taux d'échantillonnage d'un appareil de mesure, temps pendant lequel on enregistre des résultats, etc.), et affectent les données mesurées. L'estimation que l'expérimentateur fait des quantités qu'il souhaite mesurer va donc dépendre de ces variables [1].

II.1.2 Domaine d'application des plans d'expériences

La méthodologie des plans d'expériences est destinée à optimiser la conduite et l'interprétation de l'expérimentation en faisant varier simultanément les différents facteurs et en fournissant des outils d'exploitation des résultats. C'est donc une approche rationnelle pour

construire la série d'essais la plus légère possible en prenant en compte les contraintes telles que celle qui relèvent du coût ou du temps par exemple [2].

Les plans d'expériences sont utilisés dans les études industrielles en recherche et développement, vu qu'ils s'inscrivent dans une démarche générale d'amélioration de la qualité. Ils interviennent dans de nombreux domaines industriels tels que :

- ✓ Industries chimiques, pétrochimiques et pharmaceutiques ;
- ✓ Industries mécaniques et automobiles ;
- ✓ Industries métallurgiques.

Leur utilisation vise à la :

- ✓ Détermination des facteurs clés dans la conception d'un nouveau produit ou d'un nouveau procédé ;
- ✓ Optimisation des réglages d'un procédé de fabrication ou d'un d'appareil de mesure ;
- ✓ Prédiction par modélisation du comportement d'un procédé [3].

II.1.3 Modélisation et logiciels

Les plans d'expériences permettent d'organiser au mieux les essais qui accompagnent une recherche scientifique ou des études industrielles. Ils sont applicables à de nombreuses disciplines et à toutes les industries à partir du moment où l'on recherche le lien qui existe entre une grandeur d'intérêt y , tel que le rapport d'amélioration de la conductivité thermique ou autre, et des variables x_i telle que la température, et ceci dans un but d'optimisation [2, 4].

Il faut penser aux plans d'expériences si l'on s'intéresse à une fonction du type :

$$y = f(x_i) \quad (\text{II.1})$$

Raison pour laquelle il existe des logiciels pour les traiter comme *Mini-Tab* ou principalement *JMP* (*John's Macintosh Product*), pour ne citer que les plus connus [5].

Les corrélations sont basées sur une exploitation statistique de résultats expérimentaux souvent associées à des considérations physiques tandis que les modèles sont, en premier lieu, basés sur des considérations phénoménologiques enrichies par des données expérimentales, ce qui leur donne, a priori, un caractère plus universel.

II.1.4 Méthodologie des plans d'expériences

II.1.4.1 Notion d'espace expérimental

Un plan d'expériences peut être défini comme une suite d'essais organisés à l'avance, de manière à déterminer, au moyen d'un nombre réduit d'essais et avec un maximum de précision, l'influence de multiples paramètres (facteurs) sur une (ou plusieurs) propriété (s) étudiée(s) (réponses).

De manière générale, la méthode des plans d'expériences cherche à déterminer et à établir les liens existant entre deux types de variables :

- **La réponse** : grandeur physique étudiée ;
- **Les facteurs** : grandeurs physiques modifiables par l'expérimentateur, sensées influencer sur les variations de la réponse.

Plus précisément, la méthode des plans d'expériences vise aussi bien à comprendre les relations liant la réponse avec les facteurs, que les facteurs entre eux [6].

La grandeur d'intérêt, qui est généralement notée y , porte le nom de réponse. Les variables qui peuvent modifier la réponse sont appelées facteurs. On parle donc des facteurs qui influent une réponse. Les termes facteur et réponse sont universellement employés dans le domaine des plans d'expériences [5].

La construction des plans et l'interprétation des résultats dépendent en grande partie des types de facteurs utilisés dans l'étude. On distingue plusieurs types de facteurs, nous retiendrons les types de facteurs suivants : les facteurs continus, les facteurs discrets, les facteurs ordonnables et les facteurs booléens.

Un expérimentateur qui lance une étude s'intéresse à une grandeur qu'il mesure à chaque essai. Cette grandeur s'appelle la réponse, c'est la grandeur d'intérêt. La valeur de cette grandeur dépend de plusieurs variables. Au lieu du terme variable on utilisera le mot facteur. Le premier facteur peut être représenté par un axe gradué et orienté, figure (II-1). La valeur donnée à un facteur pour réaliser un essai est appelée niveau. Lorsqu'on étudie l'influence d'un facteur, en général, on limite ses variations entre deux bornes. La borne inférieure qui est le niveau bas et la borne supérieure qui est le niveau haut [5, 6].

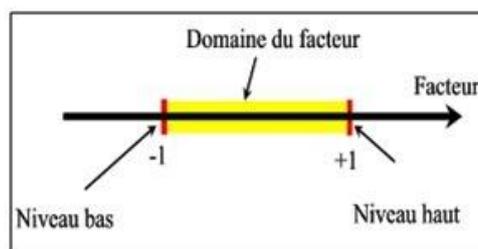


Figure II.1: Domaine du facteur [5].

S'il y a un second facteur, il est représenté, lui aussi, par un axe gradué et orienté. On le définit, comme pour le premier facteur par son niveau haut, son niveau bas et son domaine de variation. Ce second axe est disposé orthogonalement au premier. On obtient ainsi un repère cartésien qui définit un espace euclidien à deux dimensions. Cet espace est appelé l'espace expérimental (figure II.2) [5, 6].

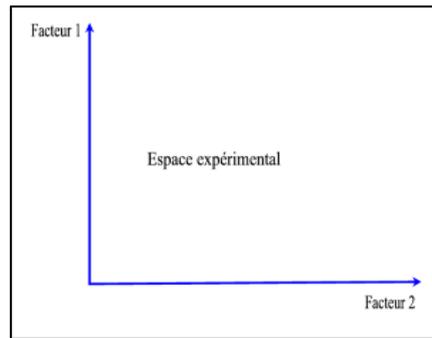


Figure II.2: Espace expérimental [5].

Le niveau x_1 du facteur 1 et le niveau x_2 du facteur 2 peuvent être considérés comme les coordonnées d'un point de l'espace expérimental. Une expérience donnée est alors représentée par un point dans ce système d'axes. Par conséquent, un plan d'expériences est représenté par un ensemble de points expérimentaux, comme montré dans la figure II.3 ci-dessous. Cet ensemble de points définit ce qu'on appelle le domaine d'étude, qui représente l'espace expérimental choisie par l'expérimentateur pour faire ses essais [6].

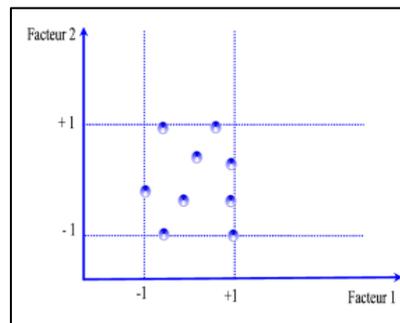


Figure II.3: Domain d'étude [5].

Les définitions qui ont été données s'appliquent bien aux variables continues. Mais il existe d'autres types de variables comme les variables discrètes. On peut encore parler d'espace expérimental mais il n'aura pas les mêmes propriétés que l'espace des variables continues. Il y a également les grandeurs ordonnables comme, par exemple, des distances qui peuvent être courtes, moyennes et longues. Là aussi, la notion d'espace expérimental existe toujours mais cet espace possède des propriétés différentes des deux premiers [6].

II.1.4.2 Notion de surface de réponse

Les niveaux x_i représentent les coordonnées d'un point expérimental et y est la valeur de la réponse en ce point. On définit un axe orthogonal à l'espace expérimental et on l'attribue à la réponse. La représentation géométrique du plan d'expériences et de la réponse nécessite un espace ayant une dimension de plus que l'espace expérimental. Un plan à deux facteurs utilise un espace à trois dimensions pour être représenté : une dimension pour la réponse, deux dimensions pour les

facteurs. A chaque point du domaine d'étude correspond à une réponse. L'ensemble de tous les points du domaine d'étude correspond à un ensemble de réponses qui se localisent sur une surface appelée la surface de réponse (figure II.4). Le nombre et l'emplacement des points est le problème fondamental des plans d'expériences. On cherche à obtenir la meilleure précision possible sur la surface de réponse tout en limitant le nombre d'expériences [6].

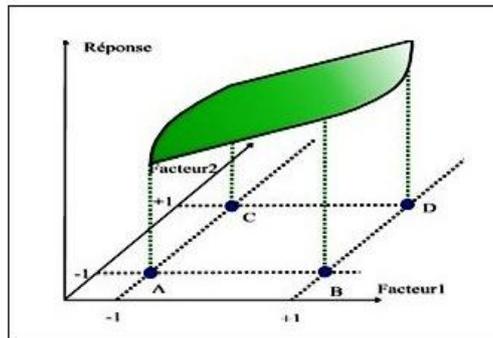


Figure II.4: Illustration de la surface de réponse [4].

II.1.4.3 Modélisation mathématique

On choisit a priori une fonction mathématique qui relie la réponse aux facteurs en prenant un développement limité de la série de Taylor-Mac Laurin. Les dérivées sont supposées être constantes et le développement prend la forme d'un polynôme de degré plus ou moins élevé :

$$y = a_0 + \sum a_i x_i + \sum a_{ij} x_i x_j + \dots + \sum a_{ii} x_i^2 + a_{ij\dots z} x_i x_j \dots x_z \quad (\text{II.2})$$

Où :

- y est la réponse ou la grandeur d'intérêt. Elle est mesurée au cours de l'expérimentation et elle est obtenue avec une précision donnée.
- x_i représente le niveau attribué au facteur i par l'expérimentateur pour réaliser un essai. Cette valeur est parfaitement connue. On suppose même que ce niveau est déterminé sans erreur (hypothèse classique de la régression).
- a_0, a_i, a_{ij}, a_{ii} sont les coefficients du modèle mathématique adopté à priori. Ils ne sont pas connus et doivent être calculés à partir des résultats des expériences.

L'intérêt de modéliser la réponse par un polynôme est de pouvoir calculer ensuite toutes les réponses du domaine d'étude sans être obligé de faire les expériences. Ce modèle est appelé "modèle postulé" ou "modèle a priori" [7].

Deux appoints doivent être apportés au modèle précédemment décrit. Le premier complément est le "manque d'ajustement". Cette expression traduit le fait que le modèle a priori est fort probablement différent du modèle réel qui régit le phénomène étudié. Il y a un écart entre ces deux modèles qui est le manque d'ajustement (*Lack of fit* en Anglais).

Le second complément est la prise en compte de la nature aléatoire de la réponse. En effet, si l'on mesure plusieurs fois une réponse en un même point expérimental, on n'obtient pas exactement le même résultat. Les résultats sont dispersés, les dispersions ainsi constatées sont appelées erreurs expérimentales. Ces deux écarts, c.à.d. manque d'ajustement et erreur expérimentale, sont souvent réunis dans un seul écart (notée e) [6].

Le modèle utilisé par l'expérimentateur s'écrit alors :

$$y = a_0 + \sum a_i x_i + \sum a_{ij} x_i x_j + \dots + \sum a_{ii} x_i^2 + a_{ij\dots z} x_i x_j \dots x_z + e \tag{II.3}$$

II.1.4.4 Types de plan d'expériences

Un plan d'expériences définit un ensemble d'expériences réparties dans le domaine expérimental. Il existe de nombreux types de plans d'expériences et le choix de l'un d'eux peut s'avérer difficile. Le principe de ce choix est de sélectionner le plan le plus avantageux, présentant le moins d'expériences possible pour obtenir le plus d'informations possible. Ce choix dépend de l'objectif fixé, des méthodes d'analyse utilisées, des contraintes expérimentales, des ressources, du comportement étudié (lié aux facteurs et aux variables d'intérêt) et de l'expertise à disposition. Nous nous contenterons ici d'expliquer brièvement les types de plan d'expériences les plus utilisées [8].

A. Plan factoriel complet à deux niveaux

Ce sont des plans très adaptés vu qu'ils sont plus rapides ainsi simples à exploiter. Ils sont notés 2^k , alors qu'ils comportent k facteurs étudiés et le 2 signifie le nombre de niveaux par facteurs. Toutes les combinaisons de niveaux sont effectuées au cours de l'expérimentation.

Ces plans peuvent être utilisés indistinctement pour les variables continues et pour les variables discrètes, pour un plan factoriel complet à 3 facteurs noté 2^3 . Les points expérimentaux sont représentés aux sommets d'un cube, comme représenté dans la Figure II.5 ;

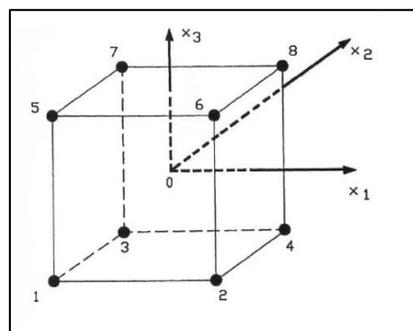


Figure II.5: Disposition des points expérimentaux d'un plan 2^3 [6].

La matrice des expériences représentée sur le Tableau II-1 traduit l'emplacement de ces points en indiquant leurs trois coordonnées en variables codées [3]:

Tableau II.1: Matrice d'un plan d'expériences 23 et résultats expérimentaux.

N° de l'essai	Z ₁	Z ₂	Z ₃	Réponse
	X ₁	X ₂	X ₃	y
1	-1	-1	-1	y ₁
2	-1	-1	1	y ₂
3	-1	1	-1	y ₃
4	-1	1	1	y ₄
5	1	-1	-1	y ₅
6	1	-1	1	y ₆
7	1	1	-1	y ₇
8	1	1	1	y ₈

B. Plans composites centrés

Un plan composite est constitué de trois parties :

- Un plan factoriel dont les facteurs prennent deux niveaux.
- Au moins un point expérimental situé au centre du domaine d'étude.
- Des points axiaux en étoile. Ces points expérimentaux sont situés sur les axes de chacun des facteurs.

Ces plans sont souvent utilisés lorsque le plan demande une expérimentation séquentielle, car ils peuvent intégrer des informations provenant d'une expérience factorielle correctement planifiée [2].

C. Plans factoriel à niveaux mixtes

Il y a autant de facteurs que l'on veut et chaque facteur prend le nombre de niveaux nécessaires à la bonne exécution de l'étude. Par exemple, un facteur peut prendre 3 niveaux, un autre 4 niveaux et un troisième 6. Ces plans sont très utilisés pour les variables discrètes [7].

II.1.4.5 Analyses statistique de l'équation de régression

a. Effets significatifs (test de Student) :

Cas où chaque essai est répété m fois ; on détermine la moyenne arithmétique des résultats des essais parallèles [6] :

$$\bar{y}_i = \frac{\sum_{u=1}^m y_{iu}}{m}, i = 1, 2, \dots, N \quad (\text{II.4})$$

Puis la variance de sondage :

$$S_i^2 = \frac{\sum_{u=1}^m (y_{iu} - \bar{y}_i)^2}{m-1}, i = 1, 2, \dots, N \quad (\text{II.5})$$

Où m est le nombre de répétition pour chaque essai et N est le nombre d'expériences. Si les variances de sondage sont homogènes, on calcule alors la variance de reproductibilité :

$$S_{rep}^2 = \frac{\sum_{i=1}^N S_i^2}{N} \quad (\text{II.6})$$

b. Validation de l'équation de régression

Avant d'accepter le modèle postulé, il est impératif de vérifier que ce dernier décrit correctement les variations de la réponse en fonction des facteurs et cela en effectuant les tests suivants :

b.1. Recherche de biais du modèle : Afin de chercher la nature des erreurs qui peuvent être engendrées par les variables non contrôlées, on a recours à la comparaison de la variance résiduelle (caractérisant la différence entre les valeurs mesurées et celle calculées) avec la variance de reproductibilité (qui caractérise la dispersion maximale) [9, 10]. L'égalité ou non des deux variances résiduelles et reproductible se basent sur le test de Fisher qui s'énonce comme suit :

$$Si F = \frac{S_{rés}^2}{S_{rep}^2} < F(0.95, N - l, n_0 - 1) \quad \left\{ \begin{array}{l} S_{rés}^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N - l} \\ S_{rep}^2 = \frac{\sum_{i=1}^{n_0} (y_i - \bar{y}_0)^2}{n_0 - 1} \end{array} \right. \quad (\text{II.7})$$

b.2. Test de signification du modèle : Lorsque le modèle est sans biais, il est possible d'effectuer le test de signification de la régression. En effet le *teste de Student* permet d'alléger le modèle mathématique en éliminant les facteurs et les interactions qui n'ont pas de conséquence significative sur la réponse [11]. Nous pouvons juger si la part de la dispersion de la réponse expliquée par le modèle est grande devant la dispersion résiduelle, en comparant les variances correspondantes par le test de Fisher :

$$F = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2 / l - 1}{\sum_{i=1}^N (y_i - \bar{y}_i)^2 / N - 1} \quad (\text{II.8})$$

\bar{y} représente la moyenne des essais donnés par :

$$\bar{y} = \frac{\sum_{i=1}^N y_i}{N} \quad (\text{II.9})$$

b.3. Coefficient de détermination : Le coefficient de détermination appelé aussi coefficient de corrélation R^2 est défini par :

$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (\text{II.10})$$

Plus le coefficient de détermination est proche de 1, plus le modèle est représentatif c'est-à-dire, meilleur.

b.4. Analyse des résidus : Lorsqu'on utilise le modèle pour estimer la réponse, on mesure généralement un écart appelé résidu défini comme la différence entre la valeur mesurée et la valeur prédite par le modèle, soit :

$$e = \hat{y}_i - y_i \tag{II.11}$$

Si la moyenne des erreurs entre la surconsommation donnée par le modèle et celle mesurée n'atteint pas 5% alors l'équation du modèle simule parfaitement l'expérience.

II.1.4.6 Fonction désirabilité

La fonction désirabilité est très utile quand il faut trouver le meilleur compromis entre plusieurs réponses. Cette fonction a été proposée par Derringer et Suich et elle figure dans de nombreux logiciels de plans d'expériences [5]. Elle est très facile à utiliser et rend de grands services. Cette fonction varie de 0 à 1. La valeur 1 correspond à une satisfaction maximale et la valeur 0 à un refus complet.

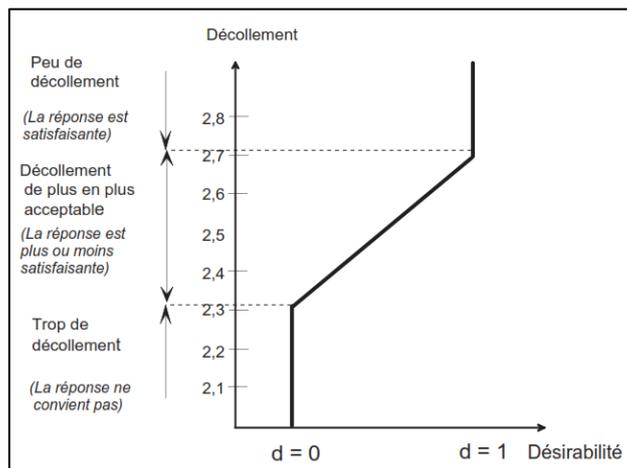


Figure II.6: La fonction désirabilité varie de 0 à 1 quand la réponse s'améliore progressivement [5].

II.2 Les Réseaux de Neurones Artificiels

II.2.1 Introduction

Les techniques de l'intelligence artificielle sont connues actuellement pour leur grande potentialité de pouvoir résoudre les problèmes liés aux processus industriels, notamment le contrôle, l'estimation et l'identification des paramètres des systèmes variant. Parmi ces techniques, on trouve les Réseaux de Neurones Artificiels (RNA), qui est une technique de traitement de données ayant des fonctionnalités d'identification, de contrôle ou de filtrage plus efficaces [12].

Depuis une vingtaine d'années, l'utilisation des réseaux de neurones artificiels (RNA) s'est étendue dans des domaines très divers de l'industrie et des services. Un Réseau de Neurones

Artificiel est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des vrais neurones. L'origine des réseaux de neurones vient de l'essai de modélisation du neurone biologique par Warren Mc Culloch et Walter Pitts [13]. Ils supposent que l'impulsion nerveuse est le résultat d'un calcul simple effectué par chaque neurone et que la pensée née grâce à l'effet collectif du réseau de neurones interconnectés. Et comme définition on peut dire que : « *Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit et toute structure hiérarchique de réseaux est évidemment un réseau* » [14].

Dans cette partie, nous présentons dans un premier temps des généralités et les concepts de base des RNA. Nous aborderons ensuite le processus d'apprentissage d'un RNA qui se réalise généralement par le choix du type d'apprentissage et de l'algorithme de mise à jour. Comme type, seul l'apprentissage à rétro-propagation du gradient d'erreur sera détaillé.

II.2.2 Domaines d'application des réseaux de neurones artificiels

Aujourd'hui, les réseaux de neurones artificiels ont de nombreuses applications dans des secteurs très variés [13] :

1. **Traitement d'images** : reconnaissance de caractères et de signatures, compression d'images, reconnaissance de forme, cryptage, classification, etc.
2. **Traitement du signal** : filtrage, classification, identification de source, traitement de la parole...etc.
3. **Contrôle** : commande de processus, diagnostic, contrôle qualité, asservissement des robots, systèmes de guidage automatique des automobiles et des avions...etc.
4. **Défense** : guidage des missiles, suivi de cible, reconnaissance du visage, radar, sonar, lidar, compression de données, suppression du bruit...etc.
5. **Optimisation** : planification, allocation de ressource, gestion et finances, etc.
6. **Simulation** : simulation du vol, simulation de boîte noire, prévision météorologique, recopie de modèle...etc.

II.2.3 Fonctionnement des réseaux de neurones

L'origine des réseaux de neurones vient de l'essai de modélisation mathématique du cerveau humain, en supposant que l'impulsion nerveuse est le résultat d'un calcul simple effectué par chaque neurone et que la pensée née grâce à l'effet collectif d'un réseau de neurone interconnecté (Figure II.7) et (Tableau II.2) [15].

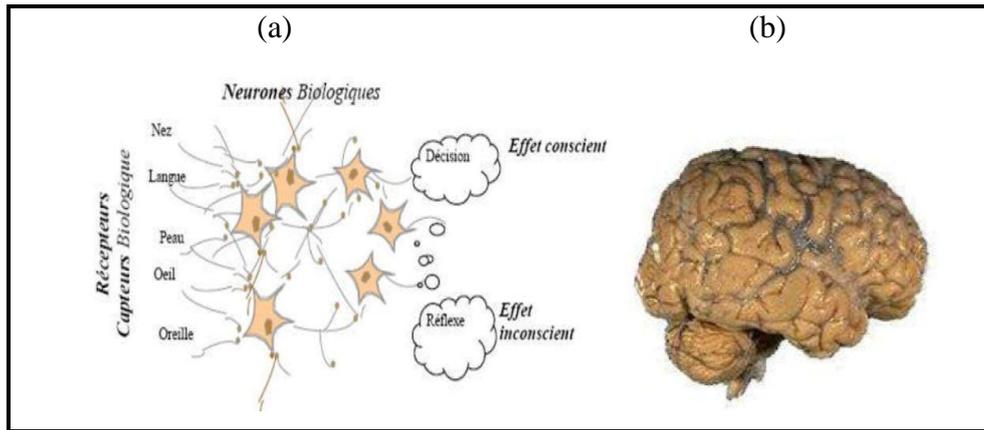


Figure II.7: Structure d'un réseau de neurone biologique et le cerveau humain [12].

Tableau II.2: Analogie entre le neurone biologique et le neurone formel [15].

<i>Neurone artificiel</i>	<i>Neurone biologique</i>
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrite
Fonction d'activation	Soma

Un réseau de neurones est un assemblage de constituants élémentaires interconnectés (appelés "neurones" en hommage à leur modèle biologique), qui réalisent chacun un traitement simple mais dont l'ensemble en interaction fait émerger des propriétés globales complexes. Chaque neurone fonctionne indépendamment des autres, de telle sorte que l'ensemble forme un système massivement parallèle. L'information est stockée de manière distribuée dans le réseau sous forme de coefficients synaptiques ou de fonctions d'activation, il n'y a donc pas de zone de mémoire et de zone de calcul, l'une et l'autre sont intimement liés.

Un réseau de neurone ne se programme pas, il est entraîné grâce à un mécanisme d'apprentissage. Les tâches particulièrement adaptées au traitement par réseau de neurones sont : l'association, la classification, la discrimination, la prévision ou l'estimation et la commande de processus complexes. Les réseaux de neurones artificiels consistent en des modèles plus ou moins inspirés du fonctionnement cérébral de l'être humain, en se basant principalement sur le concept de neurone [12].

II.2.4 Le modèle neurophysiologique [14]

Le cerveau humain contient environ 100 milliards de neurones. Ces neurones permettent, entre autre, de lire par exemple un texte tout en maintenant une respiration régulière permettant d'oxygéner le sang et actionnant le cœur qui assure une circulation efficace de ce sang nourrissant ainsi les cellules, etc. Chacun de ces neurones est par ailleurs fort complexe.

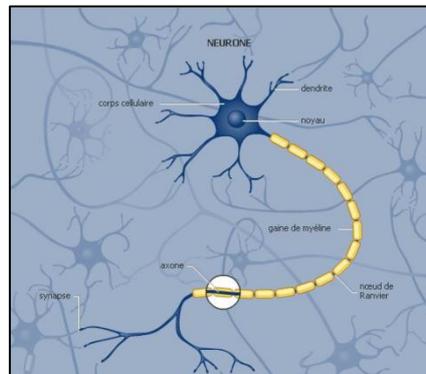


Figure II.8: Modèle d'un neurone biologique.

Essentiellement, il s'agit de tissu vivant et de chimie. Les spécialistes des neurones biologiques (neurophysiologistes) commencent à peine à comprendre quelques-uns de leurs mécanismes internes. On croit en général que leurs différentes fonctions neuronales, y compris celle de la mémoire, sont stockées au niveau des connexions (synapses) entre les neurones. C'est ce genre de théorie qui a inspiré la plupart des architectures de réseaux de neurones artificiels. L'apprentissage consiste alors soit à établir de nouvelles connexions, soit à en modifier des existantes.

Un neurone est une cellule particulière comme la montre la figure II.8. Elle possède des extensions par lesquelles elle peut distribuer des signaux (axones) ou en recevoir (dendrites).

Dans le cerveau, les neurones sont reliés entre eux par l'intermédiaire des axones et des dendrites. En première approche. On peut considérer que ces sortes de filaments sont conductrices d'électricité et peuvent ainsi véhiculer des messages depuis un neurone vers un autre. Les dendrites représentent les entrées du neurone et son axone sa sortie.

Un neurone émet un signal en fonction des signaux qui lui proviennent des autres neurones. On observe en fait au niveau d'un neurone, une intégration des signaux reçus au cours du temps, c'est à dire une sorte de sommations des signaux. En général, quand la somme dépasse un certain seuil, le neurone émet à son tour un signal électrique.

II.2.5 Modélisation d'un neurone formel [14, 15]

Les réseaux de neurones artificiels sont des modèles qui peuvent être décrits par leurs composants, leurs variables descriptives et les interactions des composants.

✓ **Structure**

Un "neurone formel" est une fonction algébrique non linéaire et bornée, dont la valeur dépend des paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées "entrées" du neurone et la valeur de la fonction est appelée sa "sortie".

Un neurone est donc avant tout un opérateur mathématique, dont on peut calculer la valeur numérique par quelques lignes de logiciel. La représentation graphique d'un neurone est comme indiqué dans la figure II.9.

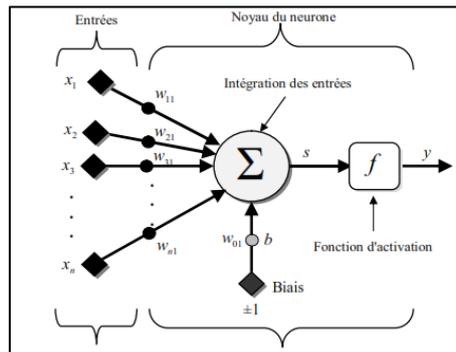


Figure II.9: Modèle d'un neurone artificiel [15].

A partir des observations de neurone biologique, découle le modèle du neurone formel (proposé par W. M. Culloch et W. Pitts en 1943) où :

- x_i : Représentent les vecteurs d'entrées, elles proviennent soit des sorties d'autres neurones, soit de stimuli sensoriels (capteur visuel, sonore...).
 - w_{ij} : Sont les poids synaptiques du neurone j , ils correspondent à l'efficacité synaptique dans les neurones biologiques ($w_{ij} > 0$ pour synapse excitatrice; $w_{ij} < 0$ pour synapse inhibitrice). Ces poids pondèrent les entrées et peuvent être modifiés par apprentissage.
 - Biais : L'entrée prend souvent les valeurs -1 ou +1 qui permet d'ajouter de la flexibilité au réseau en permettant de varier le seuil de déclenchement du neurone par l'ajustement des poids et du biais lors de l'apprentissage.
 - Noyau : Il intègre toutes les entrées ainsi le biais ; et il calcul la sortie du neurone selon une fonction d'activation (souvent non linéaire) pour donner une plus grande flexibilité d'apprentissage.
- Le modèle mathématique d'un neurone artificiel est illustré dans la figure II.9. Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat de cette somme est ensuite transformé par une fonction de transfert f qui produit la sortie y du neurone.

En suivant les notations présentées dans la section précédente, les n entrées du neurone correspondent au vecteur $x = [x_1, x_2, x_3, \dots, x_n]^T$ alors que $w = [w_{11}, w_{21}, w_{31}, \dots, w_{n1}]^T$ représente le vecteur des poids du neurone.

La sortie s de l'intégrateur est donnée par l'équation suivante :

$$s = \sum_{i=1}^n w_{i1}x_i \pm b = w_{11}x_1 + w_{21}x_2 + w_{31}x_3 + \dots + w_{n1}x_n \tag{II.12}$$

Que l'on peut aussi écrire sous forme matricielle :

$$s = w^T x \pm b \tag{II.13}$$

Cette sortie correspond à une somme pondérée des poids et des entrées plus ce qu'on nomme le biais b du neurone. Le résultat s de la somme pondérée s'appelle le niveau d'activation du neurone. Le biais b s'appelle aussi le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient positif (ou nul) ; sinon il est négatif.

✓ **Fonctions d'activations**

Différentes fonctions de transfert peuvent être utilisées comme fonction d'activation dans les RNA (tableau II.3). Les fonctions d'activations les plus utilisées sont les fonctions "seuil" (*en anglais "hard limit"*), qui sont linéaire et sigmoïde. Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée. Plus précisément, une entrée négative ne dépasse pas le seuil et la fonction retourne alors la valeur 0 (ce 0 peut être interprété comme *significativement faux*) ; alors qu'une entrée positive ou nulle ne dépasse pas le seuil et la fonction retourne la valeur 1 (*vrai*).

Utilisée dans le contexte d'un neurone, cette fonction est illustrée à la figure II.10.a. On remarque alors que le biais b dans l'expression de $y = \text{hard lim}(w^T x - b)$ détermine l'emplacement du seuil sur l'axe $w^T x$, où la fonction passe de 0 à 1 permettant ainsi de prendre des décisions binaires.

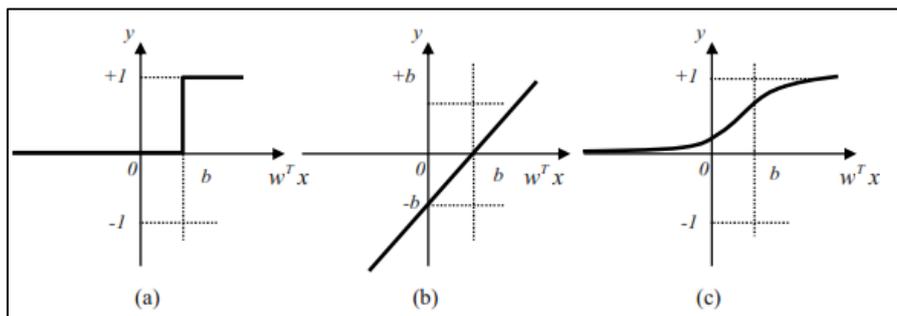


Figure II.10: Fonctions d'activations : (a) du neurone « seuil » ; (b) du neurone « linéaire », et (c) du neurone « sigmoïde ».

La fonction linéaire est très simple, elle affecte directement son entrée à sa sortie : $y = s$. Appliquée dans le contexte d'un neurone, cette fonction est illustrée à la figure II.10.b. Dans ce cas, la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $w^T x = b$.

La fonction de transfert sigmoïde est quant à elle illustrée à la figure II.10.c. Son équation est donnée par :

$$y = \frac{1}{1 + \exp^{-s}} \tag{II.14}$$

Elle ressemble soit à la fonction seuil soit à la fonction linéaire selon que l'on est loin ou près de b , respectivement. La fonction seuil est amplement non linéaire car il y a une discontinuité lorsque $w^T x = b$. De son côté, la fonction linéaire est tout à fait linéaire et elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux. Notons finalement, que la fonction "tangente hyperbolique (*tanh*)" est une version symétrique de la sigmoïde.

Tableau II.3: Différentes fonctions d'activations utilisées dans les RNA.

Nom de la fonction	Relation entrée/sortie	Icône	Nom MATALB
Seuil	$y = 0$ si $s < 0$ $y = 1$ si $s \geq 0$		hardlim
Seuil symétrique	$y = -1$ si $s < 0$ $y = 1$ si $s \geq 0$		hardlims
Linéaire	$y = s$		purelin
Linéaire saturée	$y = 0$ si $s \leq 0$ $y = s$ si $0 \leq s \leq 1$ $y = 1$ si $s \geq 1$		satlin
Linéaire saturée symétrique	$y = -1$ si $s < -1$ $y = s$ si $-1 \leq s \leq 1$ $y = 1$ si $s > 1$		satlins
Linéaire positive	$y = 0$ si $s \leq 0$ $y = s$ si $s \geq 0$		poslin
Sigmoïde	$y = \frac{1}{1 + \exp^{-s}}$		logsig
Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$		tansig
Compétitive	$y = 1$ si s maximum $y = 0$ autrement		compet

II.2.6 Architecture des réseaux de neurones

L'architecture est un concept très important qui joue un rôle déterminant dans la classification des RNA. Dans la littérature on utilise souvent le mot structure comme architecture. Chaque architecture a sa propre organisation (il s'agit de la façon dont ils sont ordonnés et connectés) qui est adapté à des applications bien spécifiques.

La majorité des réseaux de neurones utilise le même type de neurones. Quelques architectures plus rares se basent sur des neurones dédiés. L'architecture d'un réseau de neurones dépend de la tâche à apprendre. Un réseau de neurone est en général composé de plusieurs couches de neurones, des entrées jusqu'aux sorties. On distingue deux grands types d'architectures de réseaux de neurones : les réseaux de neurones non bouclés et les réseaux de neurones bouclés [12, 15].

II.2.6.1 Les réseaux de neurones non bouclés [16]

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées pour chacun de ses neurones. Un réseau de

neurones non bouclé est représenté graphiquement par un ensemble de neurones "connectés" entre eux, avec l'information circulant des entrées vers les sorties sans "retour en arrière". Si l'on représente le réseau comme un graphe dont les nœuds sont des neurones et les arêtes des "connexions" entre ceux-ci, le graphe d'un réseau non bouclé est acyclique. Le terme de "connexions" est une métaphore, car dans la très grande majorité des applications, les réseaux de neurones sont des formules algébriques dont les valeurs numériques sont calculées par des programmes d'ordinateurs et non par des objets physiques (circuits électroniques spécialisés). Néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage, car il est commode quoique trompeur. Il a même donné naissance au terme de connexionnisme.

➤ *Réseaux de neurones monocouches*

La structure d'un réseau monocouche est telle que des neurones organisés en entrée sont entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids (figure II.11).

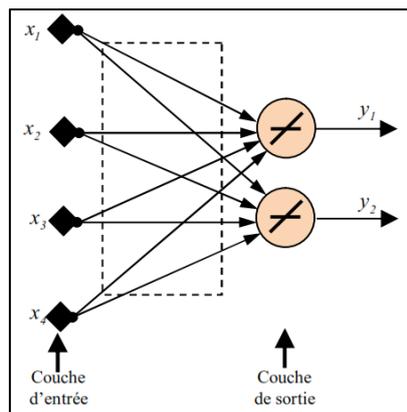


Figure II.11: Schéma d'un réseau de neurones monocouche.

➤ *Réseaux de neurones multicouches*

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones de couches avales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et ainsi de suite. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée et de neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée et couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.

La figure II.12 représente un réseau de neurones non bouclé qui a une structure particulière, très fréquemment utilisée. Il comprend des entrées, deux couches de neurones cachés et des

neurones de sortie. Les neurones de la couche cachée ne sont pas connectés entre eux. Cette structure est appelée *Perceptron multicouches* [15].

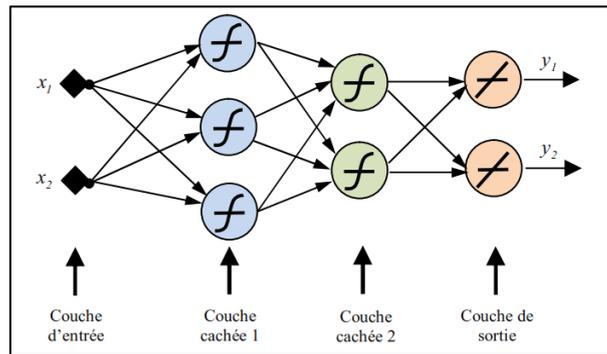


Figure II.12: Schéma d'un réseau de neurones non bouclé (Perceptron multicouches).

On note aussi que les réseaux multicouches sont beaucoup plus puissants que les réseaux simples à une seule couche. En utilisant deux couches (une couche cachée et une couche de sortie), à condition d'employer une fonction d'activation sigmoïde sur la couche cachée, on peut entraîner un réseau à produire une approximation de la plupart des fonctions avec une précision arbitraire (cela peut cependant requérir un grand nombre de neurones sur la couche cachée). Sauf dans des rares cas, les réseaux de neurones artificiels exploitent deux ou trois couches.

Les réseaux de neurones non bouclés sont des objets statiques si les entrées sont indépendantes du temps et si les sorties le sont également. Ils sont utilisés principalement pour effectuer des tâches d'approximation de fonction non linéaire, de classification ou de modélisation de processus statiques non linéaire [15, 16].

II.2.6.2 Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés dont le graphe de connexions est acyclique, les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties. Pour qu'un tel système soit causal, il faut évidemment qu'à toute boucle soit associé un retard. Un réseau de neurones bouclé est donc un système dynamique, régi par des équations différentielles ; et comme l'immense majorité des applications sont réalisées par des programmes d'ordinateurs, on se place dans le cadre des systèmes à temps discret où les équations différentielles sont remplacées par des équations aux différences finies.

Il s'agit donc de réseaux de neurones avec retour en arrière (*feedback network* ou *recurrent network*), (Figure II.13) [15, 16].

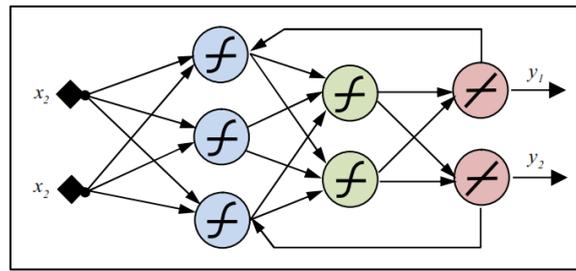


Figure II.13: Schéma de réseau de neurones bouclé.

II.2.7 L'apprentissage

Parmi les propriétés des réseaux de neurones les plus fondamentales c'est sûrement la capacité d'apprendre de son environnement et d'améliorer sa performance à travers un processus d'apprentissage.

L'apprentissage est une étape très importante du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié itérativement jusqu'à l'obtention du comportement désiré, et ce par l'ajustement des poids des neurones à une source d'information bien définie. L'apprentissage consiste également à extraire des conformités parmi les données utilisées pour l'entraînement du réseau, mais l'objectif essentiel de l'apprentissage est la résolution du problème par la prévision, la classification, etc [15].

Et comme définition on peut dire que : « *L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement* », [14].

Pour un RNA, l'apprentissage peut être considéré également comme étant le processus de la mise à jour des poids (connexion) au sein du réseau et ceci dans le but d'ajuster la réponse du réseau à l'expérience et aux exemples. Il existe plusieurs types de règles d'apprentissage qui peuvent être rassemblées en deux catégories qui sont : l'apprentissage supervisé et l'apprentissage non supervisé.

Des exemples d'utilisations de différentes règles d'apprentissage, d'architectures et d'algorithmes qui sont reliés à ces types supervisés et non supervisés sont illustrés dans les tableaux III.1 et III.2 dans l'annexe B.

II.2.7.1 Stratégies d'apprentissage

L'apprentissage au sein des différentes architectures dépend de l'architecture du réseau et de l'environnement du problème. Les deux règles d'apprentissage pour corriger les poids d'un neurone (règle de *Hebb* et de *Widrow*) ne concernent qu'un seul neurone. Ces règles peuvent servir pour mettre à jour les poids d'un neurone, de certains réseaux de neurones, mais ne peuvent être généralisées et s'appliquer à n'importe quelle architecture. Chaque architecture possède ses spécificités et nécessite une règle d'adaptation des poids qui lui est propre.

L'apprentissage n'est pas modélisable dans le cadre de la logique déductive, celle-ci en effet procède à partir de connaissances déjà établies dont on tire des connaissances dérivées. Or il s'agit ici de la démarche inverse, par observations limitées tiré des généralisations plausibles.

La notion d'apprentissage recouvre deux réalités (figure II.14) [14] :

- La mémorisation : le fait d'assimiler sous une forme dense des exemples éventuellement nombreux.
- La généralisation : le fait d'être capable, grâce aux exemples appris, de traiter des exemples distincts, encore non rencontrés, mais similaires.

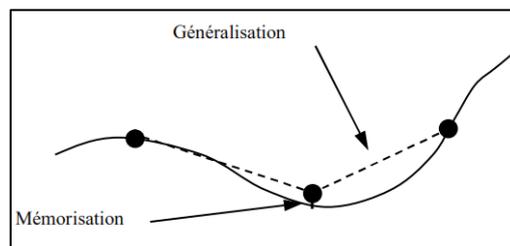


Figure II.14: Principe de l'apprentissage.

II.2.7.2 Algorithmes d'apprentissages

Définir l'architecture d'un RNA pour un problème quelconque revient à faire un choix judicieux de la taille du réseau, du nombre total de couches et de neurones, de distribution des données et des fonctions de transfert. Le choix de ces paramètres dépend de l'utilisateur.

Il n'existe pas dans la littérature pour le moment des données suffisantes qui peuvent déterminer clairement les paramètres à adopter pour résoudre un problème donné. Les différentes techniques présentées par différents auteurs sont destinées à résoudre des cas particuliers.

Un ensemble de règles bien définies permettant de réaliser un tel processus d'adaptation des poids constitue ce qu'on appelle l'algorithme d'apprentissage du réseau.

Il y a plusieurs types d'algorithmes d'apprentissage tels que : l'apprentissage par correction d'erreur, l'apprentissage à rétro-propagation du gradient d'erreur et l'apprentissage par renforcement [15].

Dans la suite de ce chapitre, nous nous sommes intéressés à l'algorithme de la rétro-propagation du gradient d'erreur (*back-propagation*).

II.2.8 Le Perceptron Multicouches (MLP)

II.2.8.1 Structure du réseau MLP

Une seule couche de neurones ne pouvant réaliser que des séparations linéaires, l'idée vient alors de rajouter des couches dites cachées pour réaliser un réseau de neurone multicouche. Dans une couche, les neurones ne sont pas connectés entre eux.

Un réseau à couches est une extension du célèbre perceptron avec une ou plusieurs couches intermédiaires appelées "cachées". Le perceptron multicouches (*Multi Layered Perceptron - MLP*) sont les réseaux de neurones les plus connus. Un perceptron est un réseau de neurones artificiel du type "feedforward", c'est-à-dire à propagation directe [12]. Le schéma de la figure II.15 montre un réseau à trois couches possédant trois entrées et une sortie. La première est celle des entrées (elle n'est cependant pas considérée comme couche neuronale par certains auteurs car elle est linéaire et ne fait que distribuer les variables d'entrées). La deuxième est dite couche cachée et constitue le cœur du réseau de neurones. La troisième, constituée ici par un seul neurone est la couche de sortie, on numérote les couches de l'entrée vers la sortie donc sur le schéma de gauche à droite, la couche cachée a trois neurones, un tel réseau est ainsi noté par 3-3-1.

On remarque sur la figure II.14, des termes x_0^m en entrée des neurones (le terme en exposant représente, non pas la fonction puissance, mais plutôt l'indice (^m) de la couche du réseau de neurones).

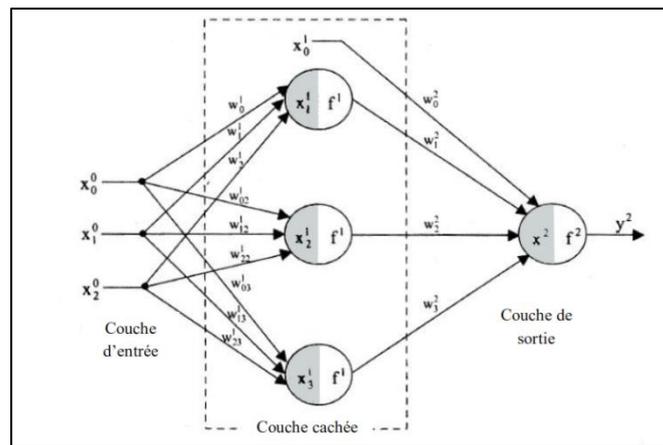


Figure II.15: Réseau de neurones de type perceptron à une couche cachée.

Le perceptron multicouche (*MLP*) est très utilisé en identification et en contrôle. Avec une couche cachée, il constitue un "Approximateur universel", qui peut approximer n'importe quelle fonction entrées/sorties (sous réserve de mettre suffisamment de neurones dans la couche cachée et d'utiliser des sigmoïdes pour les fonctions) d'activation. Bien entendu, les théorèmes mathématiques ne démontrent pas qu'un réseau à une seule couche cachée est optimal.

Malheureusement, il n'existe pas de règle générale qui donne le nombre de neurones à retenir pour la couche cachée. Le résultat le plus important est certainement le théorème de Hecht-Nielsen, où toute fonction continue peut-être implémentée exactement comme un réseau de neurones à trois couches ayant n cellules en entrée, $2n+1$ cellule en couche cachée et m cellules de sortie. Il faut bien noter que ce théorème ne donne aucune indication quant au nombre de connexion (le réseau n'est pas toujours totalement connecté), et ne garantit pas que ce nombre de neurones est optimal mais suffisant. Enfin, le réseau de neurones fait partie de Réseaux Adaptatifs Non-linéaires, et cela

signifie que ses agents (neurones) s'organisent et modifient leurs liens mutuels lors d'une procédure fondamentale qu'est l'apprentissage. Pour une tâche précise, l'apprentissage du réseau de neurones consiste donc à adapter les différents poids [12, 14, 15].

II.2.8.2 L'algorithme de la rétro-propagation du gradient d'erreur (back-propagation)

L'un des algorithmes les plus répandus est celui de la "rétro-propagation" ou "back-propagation". Cet algorithme change les poids d'un réseau dont l'architecture est fixée par l'opérateur, à chaque fois qu'un exemple $y_i = f(x_i)$ est présenté. Ce changement est fait de sorte à minimiser l'erreur entre la sortie désirée et la réponse du réseau à une entrée x_i . Ceci est réalisé grâce à la méthode de descente de gradient. A chaque itération le signal d'entrée se propage dans le réseau dans le sens entrée-sortie, une sortie est ainsi obtenue, l'erreur entre cette sortie et la sortie désirée est calculée puis par rétro-propagation "error back-propagation", des erreurs intermédiaires, correspondant à la couche cachée sont ainsi calculées et permettent l'ajustement des poids $w_{ij}(t)$ de la couche cachée [15].

L'algorithme de rétro-propagation du gradient comporte donc deux phases :

1. Propagation : à chaque étape, on présente au réseau un exemple en entrée. Cette entrée est propagée jusqu'à la couche de sortie.
2. Correction : A coup sûr, le réseau ne fournira pas exactement ce que l'on attendait. On calcule donc une erreur (en général la somme quadratique moyenne des erreurs pour tous les neurones de sortie) que l'on rétro-propage dans le réseau. Ce processus est interrompu dès que l'erreur globale est estimée suffisante.

La figure II.16 montre le processus de rétro-propagation.

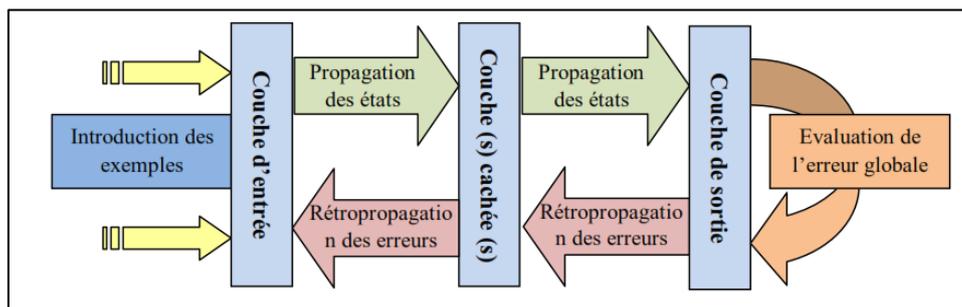


Figure II.16: Apprentissage des réseaux de neurone par l'algorithme de rétro-propagation.

II.2.9 Conclusion

Les plans d'expériences permettent d'organiser au mieux les essais qui accompagnent une recherche scientifique ou des études industrielles. Ils sont applicables à de nombreuses disciplines et à toutes les industries à partir du moment où l'on cherche le lien qui existe entre une grandeur d'intérêt « y » et des variables « x_i ». L'utilisation des plans d'expériences permet de limiter le

nombre d'essais et admet de quantifier l'impact des paramètres expérimentaux sur le phénomène étudié. Pour cela, il faut suivre des règles mathématiques et adopter une démarche rigoureuse.

Les réseaux de neurones formels, tels que nous les avons définis, possèdent une propriété remarquable qui est à l'origine de leur intérêt pratique dans des domaines très divers. Le choix d'utiliser tel ou tel type de réseau de neurones dépend de l'application mais aussi des capacités de traitement du processeur sur lequel ils s'exécutent. L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux neuronaux, cependant il existe plusieurs algorithmes utilisés pour faire l'apprentissage des réseaux multicouches, et en général, l'algorithme d'apprentissage de rétro-propagation (RP) est très utilisé.

De même, pour la conclusion de ce chapitre, on rappellera ce qui suit :

L'application de la méthode des plans d'expériences ainsi que la méthode des réseaux des neurones dans le domaine de transfert de chaleur des nanofluides, permet de générer des modèles mathématiques décrivant l'influence des différents facteurs sur la conductivité thermique.

II.3 Références

- [1] Sagnol, G. (2010). Plans d'expériences optimaux et application à l'estimation des matrices de trafic dans les grands réseaux: programmation conique du second ordre et sous-modularité, Doctoral dissertation, Mines Paris Tech, Paris.
- [2] Ait Bahcine, Y. (2018). Application de la méthodologie des plans d'expérience a la robustesse des méthodes analytiques : étude de cas hydrochlorothiazide/valsartan et ridogrel. Doctoral dissertation, Université du Mohammed v rabat. Maroc.
- [3] Triboulet, P. (2008). Notions de bases sur les plans d'expériences. Lycée Niepce-Chalon Sur Saône. France.
- [4] Goupy, J. (1999). Plans d'expériences pour surfaces de réponse. Edition Dunod, Paris.
- [5] Goupy, J. L. (1990). Etude comparative de divers plans d'expériences. Revue de statistique appliquée, 38(4), 5-44.
- [6] Goupy, J. (2000). Modélisation par les plans d'expériences. Techniques de l'ingénieur. Mesures et contrôle, R275-1.
- [7] Goupy, J. (2006). Les plans d'expériences, Tutoriel. Revue Modulad, 75.
- [8] BLONDET. G, « Système à base de connaissances pour le processus de plan d'expériences numériques », Sorbonne Universités ; Juin 2017.
- [9] Feinberg, M. (2004). Validation des méthodes d'analyses, Edition Dunod, Paris, 2004.
- [10] Neuilly, M. (1993). Modélisation et estimation des erreurs de mesure. Edition Lavoisier, Paris.
- [11] Sado, G., Sado, M.C. Les plans d'expérimentation à l'assurance qualité, Edition AFNOR,

2000.

- [12] Djeriri, Y., Boudjema, Z. (2017). Commande robuste par la logique floue et les réseaux de neurones artificiels de la GADA : étude comparative. *Revue des Energies Renouvelables*, 20(1), 147-160.
- [13] Baghli, L. (1999). Contribution à la commande de la machine asynchrone, utilisation de la logique floue, des réseaux de neurones et des algorithmes génétiques'', Doctoral dissertation, Henri Poincaré Nancy-I, France.
- [14] Touzet, C. (1992). Les réseaux de neurones artificiels, introduction au connexionnisme : cours, exercices et travaux pratiques. Ec2, Collection de l'EERI, Id : hal-01338010
- [15] Brakni, E. M. (2011). Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM, Doctoral dissertation, Université du Québec en Abitibi-Témiscamingue, Canada.
- [16] Oussar, Y. (1998). Réseaux d'ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus, Doctoral dissertation, Université Pierre et Marie Curie-Paris VI, France.

A decorative graphic featuring three green circles of varying sizes and two thin green lines. One line starts from the top left and ends near the middle of the smaller circle. Another line starts from the top right and ends near the bottom of the largest circle. The circles have a slight shadow effect.

Chapitre III

III.1 Introduction

Afin d'améliorer le taux de transfert de chaleur des fluides, de nombreux chercheurs ont tenté d'augmenter leur conductivité thermique. L'amélioration des propriétés thermiques des fluides caloporteurs se fait en y insérant une phase solide de conductivité thermique très élevée ; ainsi les nanofluides obtenus présentent une conductivité thermique significativement plus élevée que les fluides de base [1–5]. Cette amélioration augmente avec l'augmentation de la concentration de nanoparticules. Toutefois, dans leur développement et leur exploitation, il convient de trouver un compromis entre des propriétés thermiques améliorées tout en maîtrisant leur viscosité (qui ne doit pas être trop importante dans les échangeurs par exemple) et leur stabilité (qui doit être assurée), sans quoi les propriétés du fluide peuvent être modifiées. Plusieurs paramètres peuvent jouer un rôle dans l'efficacité des nanofluides comme la concentration et la nature des nanoparticules, leur densité, leur type, leur taille, leur aspect, la température, le fluide de base, la présence d'un surfactant, etc...

Les propriétés thermophysiques, à savoir la conductivité thermique, la viscosité dynamique, la capacité thermique et la masse volumique, des fluides sont fortement modifiées par l'ajout de nanoparticules. Cette modification dépend du type de matériau des fluides de base et des particules, leur taille, leur concentration, la température du milieu, etc.

Les propriétés thermophysiques des nanofluides peuvent être contrôlées par les spécifications chimiques et physiques du fluide de base et des nanoparticules.

La conductivité thermique des nanofluides est l'un des facteurs qui jouent un rôle important sur les performances de transfert de chaleur. Ainsi, l'utilisation d'un type approprié de nanofluides est très importante pour améliorer la vitesse de transfert de chaleur [6, 7].

Cependant, les résultats des différentes recherches illustrent de larges écarts et incohérences dans les valeurs de la conductivité thermique des nanofluides en raison de différents paramètres, tels que la différence dans les techniques de production et de stabilisation des nanofluides, la caractérisation des nanofluides ainsi que les méthodes de mesure de la conductivité thermique [8].

Il existe également une forte corrélation entre la conductivité thermique des nanofluides et divers paramètres, à savoir : la fraction volumique des nanoparticules, le matériau des particules, leur taille et leur forme, le type et la température du fluide de base, la capacité thermique spécifique, le type de surfactant et la densité [9–17].

L'objectif général de l'utilisation des nanofluides est d'avoir des propriétés thermophysiques optimales à des fractions volumiques minimales de particules. De plus, il a

été rapporté que la conductivité thermique des nanofluides augmente avec l'augmentation de la concentration de nanoparticules [7, 18–20].

Il a également été révélé que le taux d'amélioration de la conductivité thermique diminue avec celui du fluide de base, alors qu'il est directement proportionnel à la conductivité thermique des nanoparticules [21, 22]. Néanmoins, pour une certaine concentration de nanoparticules, il est montré que pour une conductivité thermique plus faible le coefficient de transfert thermique (sera) est amélioré. Ceci est en accord avec les modèles conventionnels comme celui de Maxwell. D'autre part, il a été montré par Alrashed et al [5] que l'amélioration de la conductivité thermique des nanofluides est indépendante du fluide de base.

Un autre facteur important affectant la conductivité thermique des nanofluides est la taille des nanoparticules, en effet il a été confirmé que la conductivité thermique la plus élevée est obtenue par une distribution uniforme de petites particules [21]. On suppose également qu'une augmentation de la surface spécifique des nanoparticules pourrait conduire à une augmentation de la conductivité thermique effective des nanofluides, car le transfert de chaleur entre les particules et le fluide de base se produit à l'interface particule/fluide. De plus, le mouvement Brownien des nanoparticules pourrait être intensifié par la réduction de la taille des particules. On estime donc que ce dernier est l'un des facteurs les plus importants pour améliorer le transfert de chaleur des nanofluides [21, 23].

La forme des nanoparticules est un autre paramètre affectant le degré d'amélioration de la conductivité thermique des nanofluides [24]. Le taux de rehaussement des particules allongées est supérieur à celui des particules sphériques [25]. En général, une diminution de la sphéricité des nanoparticules conduit à une augmentation de la conductivité thermique des nanofluides.

Généralement, la conductivité thermique des nanofluides est plus sensible à la température et l'augmentation de la température entraîne une amélioration de la conductivité thermique [4, 20, 26]. De nombreuses études ont montré l'existence d'une température optimale à laquelle la conductivité thermique des nanofluides est maximale [7].

De plus, le pH a un effet sur la conductivité thermique des nanofluides car son taux d'amélioration augmente avec l'acidité [17].

Le taux d'amélioration de la conductivité thermique peut aussi être affecté par les tensioactifs et les additifs utilisés afin d'empêcher l'agglomération des particules [14, 27].

Un résumé des études expérimentales sur la conductivité thermique des nanofluides peut être trouvé dans la référence [28]. Et une revue complète et détaillée des différents modèles peut être également trouvée dans les références [29, 30].

En raison des écarts importants et incohérences des résultats obtenus par les différentes méthodes, des recherches supplémentaires doivent être effectuées afin d'élucider les effets de la conductivité thermique des nanofluides.

En conséquence, le présent travail de recherche vise à trouver une nouvelle corrélation qui prend en compte tous les paramètres qui influent sur la conductivité thermique en utilisant des données expérimentales élargie et étendues.

Donc, dans ce chapitre, un modèle mathématique est développé pour prédire la conductivité thermique des nanofluides d'Oxydes Métalliques/Eau. Quatre facteurs d'influence majeurs sur la conductivité thermique des nanofluides ont été sélectionnés ; et un plan d'expérience (Design of Experiments DOE) avec la méthode ANOVA sont utilisés pour déterminer les effets de ces facteurs et leurs interactions. Une méthode factorielle complète à deux niveaux est considérée pour chaque facteur [2], puis les résultats sont analysés. Cette modélisation est basée sur des données expérimentales recueillies dans la littérature, puis les résultats prédits ont été comparés à ceux d'autres modèles ainsi qu'aux résultats expérimentaux.

La nouveauté dans le présent travail est l'utilisation seulement des facteurs significatifs, nécessitant ainsi des données expérimentales et du temps de calcul moindres. En outre, les conditions de fonctionnement sont à basse température et à fraction volumique moyennes, qui diffèrent de la majorité des modèles empiriques et statistiques utilisés (qui sont en générale appliqués pour des plages de températures plus élevées). Par conséquent, le but de cette étude est de trouver un nouveau modèle de prédiction de la conductivité thermique de trois types de nanofluides pour des basses températures et des fractions volumique moyenne.

III.2 Position du problème

III.2.1 Caractéristiques des matériaux

Les conductivités thermiques des fluides ordinaires sont plutôt faibles, donc afin d'améliorer le transfert de chaleur des fluides, différents types de nanoparticule de conductivité thermique élevée sont utilisées. En raison des caractéristiques élevées de conductivité thermique et de performance de transfert de chaleur, les nanofluides sont

devenus un choix très attrayant pour des applications pratiques dans les systèmes d'ingénierie thermique.

Les données expérimentales utilisées dans cette étude sont extraites de la littérature [31–35] ; et les détails sont présentés dans le tableau III.1.

Les nanofluides utilisées dans le présent travail sont les nanofluides d'oxyde métallique, ce sont les types les plus utilisées dans le transfert de chaleur en raison de leur faible coût. Les nanoparticules d'oxyde métallique sont produites par des méthodes conventionnelles, elles sont plus stables que les nanoparticules métalliques [36]. Trois types de nanoparticules d'oxyde métallique sont étudiés : les Oxydes d'Aluminium (Alumine) Al_2O_3 , Oxydes de Titane (Titania) TiO_2 et Oxydes de Cuivre CuO [37–39]. Les propriétés thermophysiques correspondantes du fluide de base (Eau) et des phases solides sont données dans le tableau III.2 [40]. Ce dernier présente les propriétés thermophysiques utilisées dans cette étude.

Tableau III.1: Caractéristiques des nanofluides à base d'eau adoptées dans ce travail.

Nanoparticules	Fraction volumique (%)	Diamètre de NP (nm)	Température (K)	Chercheurs
CuO Al_2O_3	0–18 1–4	29, 28.6 20, 25, 28	température ambiante	Aminian [31]
CuO Al_2O_3	0–5 0–5	28.5 20, 25	Différente température	Kazemi-Beydokhti et al. [32]
TiO_2	0.2–2	21	288–308	Duangthongsuk et al. [33]
TiO_2	0–8	21	288–338	Yiamsawasd et al. [34]
Al_2O_3 TiO_2	1–4 1–6	30±10 30–50±10	274–313	Longo et al. [35]

Tableau III.2: Propriétés thermophysiques de l'eau et des nanoparticules sélectionnées.

Propriétés thermophysiques		μ [kg/m.s]	ρ [Kg/m ³]	C_p [J/kg. K]	K [W/m.K]
Fluide de base	Eau (H_2O)	0.000912	997.047	4184	0.6063
Nanoparticules	Alumine (Al_2O_3)	/	3970	765	40
	Oxydes de Titane (TiO_2)	/	4250	686.2	8.9538
	Oxydes de Cuivre (CuO)	/	6500	535.6	20

III.2.2 Méthodologie

La méthode de plan factoriel complet est une technique puissante, rapide et avantageuse, utilisée pour obtenir la meilleure optimisation. Cette conception nous permet de

déterminer les effets sur la réponse de chacun des niveaux de facteurs. De plus, elle prend en considération toutes les combinaisons entre niveaux de facteurs ainsi que les effets des interactions entre facteurs. Cette technique est utilisée pour réduire le nombre d'expériences, le temps et le coût global du processus avec une meilleure réponse. L'importance de cette méthode est montrée par différentes études utilisant des conceptions expérimentales [41, 42].

III.2.3 Choix de la réponse, des facteurs et du type de plan correspondant

Les différents facteurs pris en compte dans ce travail sont les plus influents sur la conductivité thermique des nanofluides ; à savoir la fraction volumique de nanoparticules, la température, le diamètre des nanoparticules et les types de nanoparticules. La grandeur d'intérêt (réponse) est alors le rapport de conductivité thermique du nanofluide sur celle du fluide et on la note comme : (k_{nf}/k_f) . On constate que les trois premiers facteurs sont des facteurs continus tandis que le dernier facteur est un facteur discret qui dépend du type de nanoparticules.

En ce qui concerne la méthode des plans d'expériences, on a utilisé les plans factoriels à niveaux mixtes avec le modèle correspondant de premier ordre.

III.2.4 Modèle mathématique

Dans cette étude, une méthode des plans d'expériences est adoptée pour optimiser la conductivité thermique des nanofluides. La technique (DOE) est réalisée pour identifier les variables clés qui affectent le taux de conductivité thermique TCR (i.e. k_{nf}/k_f) et pour déterminer à quels niveaux ces facteurs doivent être conservés dans le but de réduire les erreurs de mesure. La méthode de plan factoriel complet est utilisée afin de permettre l'étude des effets causés par les facteurs indépendants ainsi que les interactions entre ces facteurs [43, 44].

L'utilisation des variables centrées réduites présente l'intérêt de pouvoir généraliser la théorie des plans d'expériences quels que soient les facteurs ou les domaines d'études retenus. Remplacer les variables naturelles par les variables codées va permettre d'avoir pour chaque facteur le même domaine de variation (entre le niveau bas codé -1 et le niveau haut codé +1).

Le tableau III.3 montre les facteurs sélectionnés et leurs domaines de variation. Le domaine de variation des facteurs doit permettre de couvrir la zone optimale requise de la conductivité thermique des nanofluides, qui présente le domaine réel d'utilisation des facteurs dans cette partie. Le choix de l'intervalle de chaque facteur n'est pas aléatoire, il est selon les données expérimentales existant dans cette zone de transfert de chaleur.

Le logiciel JMP (*John's Macintosh Product*), conçu pour faciliter au maximum la réalisation de ces opérations en assurant le suivi complet des calculs des plans d'expériences, est utilisé. Les données expérimentales sont données dans le tableau III.2

La matrice d'expériences récapitulant l'ensemble des essais comprend plusieurs colonnes : la première identifie les essais, les suivantes indiquent les états des facteurs exprimés en "unités codés" ; chaque colonne étant représentative d'un facteur. La dernière colonne indique les réponses obtenues pour chaque essai. Les lignes inférieures rappellent les valeurs des niveaux en unités naturelles. Le tableau III.4 présente une matrice d'expériences pour 3 facteurs à 2 niveaux.

Un plan factoriel complet à deux niveaux pour trois facteurs indépendants est considéré : la fraction volumique (X_1), la température (X_2) et le diamètre des nanoparticules (X_3) ; avec deux niveaux factoriels codés comme -1 et $+1$ (niveaux bas et haut respectivement). Les types de nanoparticules (X_4) sont codés comme L_1 pour (Al_2O_3), L_2 pour (TiO_2) et L_3 pour (CuO). Un plan factoriel complet 2^3 (c'est-à-dire que trois facteurs varient sur deux niveaux) pour trois types de nanoparticules est utilisé. Par conséquent, un total de vingt-quatre essais expérimentaux est suggéré pour analyser l'interaction de chaque niveau (tableau III.4). Le rapport (k_{nf}/k_f) est considéré comme le facteur de réponse (facteur dépendant). Les résultats sont analysés et tracés avec des intervalles de confiance à 95% à l'aide du logiciel JMP.

III.3 Résultats et discussion

La corrélation obtenue prend la forme d'un polynôme et le modèle mathématique généré par la méthode des plans d'expérience est de la forme suivante :

$$\begin{aligned}
 Y = & \underbrace{1.2871875}_{a_0} + \underbrace{0.04789}_{a_1} * X_1 - \underbrace{0.214930833}_{a_2} * X_2 - \underbrace{0.0628004}_{a_3} * X_3 + \underbrace{\begin{cases} L1 \rightarrow 0.228885 \\ L2 \rightarrow -0.2098875 + X_1 * (X_2 * \\ L3 \rightarrow -0.0198875 \end{cases}}_{X_4} \\
 & \underbrace{-0.013795}_{a_{12}} + X_2 * (X_3) * \underbrace{0.064382916}_{a_{23}} + X_2 * (X_4) \underbrace{\begin{cases} L1 \rightarrow 0.036285 \\ L2 \rightarrow -0.0118625 + X_2 * (X_4) \\ L3 \rightarrow -0.0244225 \end{cases}}_{a_{14} X_4} \\
 & \underbrace{\begin{cases} L1 \rightarrow -0.237329166 \\ L2 \rightarrow 0.2153258366 + X_3 * (X_4) \\ L3 \rightarrow 0.022003333 \end{cases}}_{a_{24} X_4} \underbrace{\begin{cases} L1 \rightarrow 0.0559529166 \\ L2 \rightarrow 0.058566666 + X_2 * \\ L3 \rightarrow -0.114519583 \end{cases}}_{a_{34} X_4}
 \end{aligned}$$

$$\left\{ X_3 * (X_4) \right\} \begin{cases} L1 \rightarrow -0.055947916 \\ L2 \rightarrow -0.071206666 + X_1 * \\ L3 \rightarrow 0.1271545833 \end{cases} \left\{ X_2 * (X_4) \right\} \begin{cases} L1 \rightarrow -0.0313325 \\ L2 \rightarrow 0.0226025 \\ L3 \rightarrow 0.0087300 \end{cases} \quad (\text{III.1})$$

$\underbrace{\hspace{15em}}_{a_{234} X_4} \qquad \qquad \qquad \underbrace{\hspace{15em}}_{a_{124} X_4}$

Le modèle obtenu a pour forme générale :

$$Y = 1.083716666 + (0.032505833 + C_1)X_1 + (0.0061325 + C_2)X_2 + (-0.008745416 + C_3)X_3 + (-0.005212916)X_2X_3 + (C_4)X_1X_2 + (C_5)X_1X_3 + (0.00418375 + C_6)X_1X_2X_3 + C_7 \quad (\text{III.2})$$

Avec : $X_1 = \frac{\phi - 0.025}{0.015}$, $X_2 = \frac{T - 296.5}{1.5}$, $X_3 = \frac{d_p - 0.000000025}{0.000000004}$, et $C_1, C_2, C_3, C_4, C_5, C_6$ et C_7 sont des constantes dépendant du type de nanoparticule et sont déterminées par leurs propriétés physiques. Les valeurs de ces constantes pour chaque nanoparticule sont données dans le tableau III.5.

Tableau III.3: Les facteurs sélectionnés à différents niveaux du plan factoriel.

Facteurs	niveaux bas (-1)	niveaux haut (+1)
(X_1) fraction volumique (%)	1	4
(X_2) Température (K)	295	298
(X_3) diamètre des nanoparticules (nm)	21	29

Les modèles partiels de chacun des trois types de nanofluides sont :

$$\begin{aligned} Al_2O_3: \quad Y = & 1.0640665 + 0.036458749 X_1 + 0.00429625 X_2 + 0.00165375 X_3 \\ & - 0.005212916 X_2X_3 + 0.00021375 X_1X_2 + 0.000518333 X_1X_3 \\ & + 0.00179125 X_1X_2X_3 \end{aligned} \quad (\text{III.4})$$

$$\begin{aligned} TiO_2: \quad Y = & 1.080645 + 0.036027499 X_1 + 0.000395 X_2 - 0.0039375 X_3 \\ & - 0.005212916 X_2X_3 + 0.0076375 X_1X_2 + 0.004548333 X_1X_3 \\ & - 0.00080875 X_1X_2X_3 \end{aligned} \quad (\text{III.5})$$

$$\begin{aligned} CuO: \quad Y = & 1.106438749 + 0.02503125 X_1 + 0.01370625 X_2 - 0.023656249 X_3 \\ & - 0.005212916 X_2X_3 - 0.00785125 X_1X_2 - 0.005066666 X_1X_3 \\ & + 0.0115675 X_1X_2X_3 \end{aligned} \quad (\text{III.6})$$

Tableau III.4: Matrice d'expérience.

Nanoparticules	N° d'essai	Facteurs indépendants				Facteurs dépendants $Y = k_{nf}/k_f$
		X_1	X_2	X_3	X_4	
		ϕ	T	dp	Np	
Al ₂ O ₃	01	-1	-1	-1	L1	1.017
	02	1	-1	-1	L1	1.09
	03	-1	1	-1	L1	1.02895
	04	1	1	-1	L1	1.100320
	05	-1	-1	1	L1	1.0257
	06	1	-1	1	L1	1.093
	07	-1	1	1	L1	1.025400
	08	1	1	1	L1	1.105400
TiO ₂	09	-1	-1	-1	L2	1.052300
	10	1	-1	-1	L2	1.096330
	11	-1	1	-1	L2	1.047505
	12	1	1	-1	L2	1.130000
	13	-1	-1	1	L2	1.047070
	14	1	-1	1	L2	1.111920
	15	-1	1	1	L2	1.018215
	16	1	1	1	L2	1.115060
CuO	17	-1	-1	-1	L3	1.057
	18	1	-1	-1	L3	1.154
	19	-1	1	-1	L3	1.136
	20	1	1	-1	L3	1.16
	21	-1	-1	1	L3	1.05835
	22	1	-1	1	L3	1.088200
	23	-1	1	1	L3	1.0609
	24	1	1	1	L3	1.110300

Tableau III.5: Valeurs des constantes.

Nanoparticules	Constantes						
	$C_1 \times 10^{-4}$	$C_2 \times 10^{-4}$	$C_3 \times 10^{-4}$	$C_4 \times 10^{-4}$	$C_5 \times 10^{-4}$	$C_6 \times 10^{-4}$	$C_7 \times 10^{-4}$
Al ₂ O ₃	39.52	-18.36	103.99	2.13	5.18	-23.92	-196.5
TiO ₂	35.21	-57.37	45.16	76.37	45.48	-49.92	-30.71
CuO	-74.74	75.73	-149.1	-78.51	-50.66	73.85	227.22

III.3.1 Test du modèle proposé

Le modèle obtenu est testé pour validation par la comparaison du rapport de conductivité thermique (k_{nf}/k_f) des valeurs prédites avec celles réelles, tout en tenant compte de l'erreur standard (Figure III.1). Il est clairement montré que toutes les valeurs de TCR sont dans la ligne centrale (valeurs abscisses égale aux valeurs des ordonnées) et que la valeur de RMSE (Root Mean Square Equals) est égale à seulement (0,0074). De plus, la proportion de la variation autour de la moyenne exprimée par le modèle (linéaire ou polynomiale) représenté par (R^2), a pour valeur égale à (0,99). Ceci indique que le modèle de TCR fournit une bonne corrélation et que les valeurs prédites et expérimentales s'adaptent parfaitement.

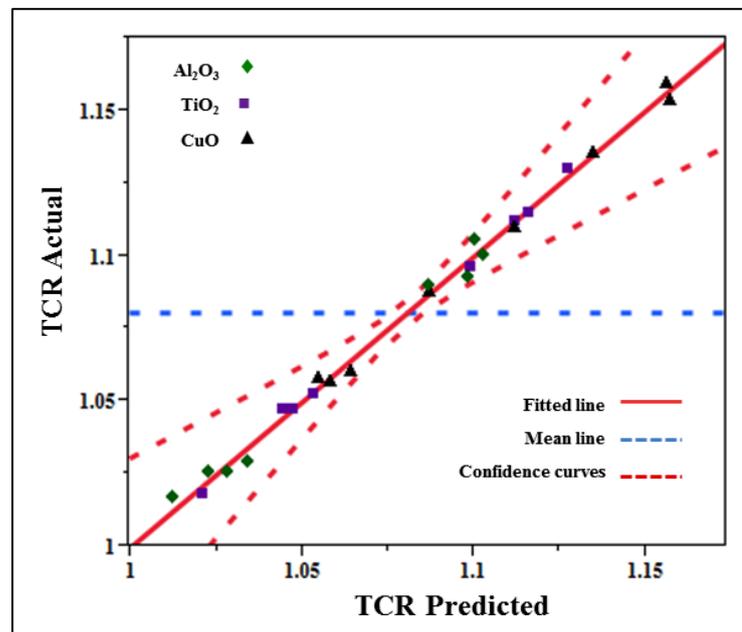


Figure III.1: les valeurs actuelles de TCR en fonction des valeurs prédites.

(P value=0.0013, R square=0.99, RMSE=0.0074)

Le tableau (III.6) donne les paramètres estimés avec leurs erreurs types ainsi que le t-test correspondant à chaque valeur de variable indépendante. Les résultats obtenus montrent que toutes les erreurs types sont de très faibles valeurs ($<0,003$) et que les probabilités correspondantes indiquent que les résultats sont statistiquement significatifs représentés par (*).

L'analyse de variance (ANOVA) pour un plan factoriel complet du modèle polynomial a été utilisée afin d'évaluer l'effet de chaque paramètre sur le modèle de TCR. La méthode statistique d'ANOVA est utile, non seulement pour déterminer l'influence de n'importe quels paramètres apportant une contribution aux résultats expérimentaux mais aussi pour interpréter les données expérimentales. Le tableau (III.7) montre les résultats d'ANOVA obtenu pour TCR. On remarque que le modèle proposé est significatif donnant une valeur de $P=0,0013$. En outre, le niveau de confiance pour les termes linéaires X_1 ($P<0,0001$), X_3 ($P<0,0045$) et X_4 ($P<0,0008$) sont les plus significatifs sur TCR, tandis que X_2 ($P<0,0157$) est toutefois significatif. La plupart des termes carrés et leurs interactions sont également très significatives.

De même, on peut voir à partir du tableau (III.7) que la fraction volumique des nanoparticules est le facteur ayant la plus grande influence sur le modèle de TCR, car elle a une valeur F très élevée (F-value = 457.0790). Par conséquent, la fraction volumique est le facteur le plus significatif sur ce modèle. Également, le diamètre des nanoparticules a un effet significatif sur TCR avec (F-value = 33.0849), ce qui montre que le diamètre est autant important. Par contre, la température qui a un effet inférieur à celui des autres paramètres principaux avec une valeur F-value de 16,26, a également un effet significatif sur la réponse. En ce qui concerne les interactions, on constate que les termes ($X_2 \times X_3$, $X_3 \times X_4$ et $X_1 \times X_2 \times X_4$) ont des effets significatifs sur TCR ; cependant le reste des interactions ont un effet non significatif sur la réponse, car la valeur de leurs probabilités ($P>0,05$). De plus, les valeurs R^2 et R^2 ajustées de 0,99 et 0,97 respectivement, sont très proches de 1 ; suggérant une forte relation entre les variables et qu'il y a une corrélation élevée entre les valeurs expérimentales et ajustées. Cela confirme que le modèle obtenu présente une excellente capacité prédictive.

Tableau III.6: Prédiction de modèle et les erreurs standards.

Term	Estimation	Std Error	t Ratio	Prob> t
Intercept value a_0	1.08037167	0.00152043	710.57	<0.0001*
$X_1(0,01,0,04)$	0.03250583	0.00152043	21.38	<0.0001*
$X_2(295,298)$	0.0061325	0.00152043	4.03	0.0157*
$X_3(2,1e-8,2,9e-8)$	-0.00874542	0.00152043	-5.75	0.0045*
$X_4[L1]$	-0.01965042	0.00215021	-9.14	0.0008*
$X_4[L2]$	-0.00307167	0.00215021	-1.43	0.2263
$X_4[L3]$	0.02272208	0.00215021	10.57	0.0005*
$X_1 \times X_4[L1]$	0.00395292	0.00215021	1.84	0.1399
$X_1 \times X_4[L2]$	0.00352167	0.00215021	1.64	0.1768
$X_1 \times X_4[L3]$	-0.00747458	0.00215021	-3.48	0.0254*
$X_2 \times X_3$	-0.00521292	0.00152043	-3.43	0.0266*
$X_2 \times X_4[L1]$	-0.00183625	0.00215021	-0.85	0.4412
$X_2 \times X_4[L2]$	-0.0057375	0.00215021	-2.67	0.0559
$X_2 \times X_4[L3]$	0.00757375	0.00215021	3.52	0.0244*
$X_3 \times X_4[L1]$	0.01039917	0.00215021	4.84	0.0084*
$X_3 \times X_4[L2]$	0.00451167	0.00215021	2.1	0.1039
$X_3 \times X_4[L3]$	-0.01491083	0.00215021	-6.93	0.0023*
$X_1 \times X_2 \times X_4[L1]$	0.00021375	0.00215021	0.1	0.9256
$X_1 \times X_2 \times X_4[L2]$	0.0076375	0.00215021	3.55	0.0238*
$X_1 \times X_2 \times X_4[L3]$	-0.00785125	0.00215021	-3.65	0.0217*
$X_1 \times X_3 \times X_4[L1]$	0.00051833	0.00215021	0.24	0.8214
$X_1 \times X_3 \times X_4[L2]$	0.00454833	0.00215021	2.12	0.1019
$X_1 \times X_3 \times X_4[L3]$	-0.00506667	0.00215021	-2.36	0.078
$X_1 \times X_2 \times X_3$	0.00418375	0.00152043	2.75	0.0513
$X_1 \times X_2 \times X_3 \times X_4[L1]$	-0.0023925	0.00215021	-1.11	0.3282
$X_1 \times X_2 \times X_3 \times X_4[L2]$	-0.0049925	0.00215021	-2.32	0.081
$X_1 \times X_2 \times X_3 \times X_4[L3]$	0.007385	0.00215021	3.43	0.0264*

(* Signifiant selon la valeur de probabilité ≤ 0.05)

Tableau III.7: Analyse de variance ANOVA pour TCR.

source	SS	DF	MS	F-value	Prob > F
Model	0.04270618	19	0.0022477	40.5130	0.0013*
X ₁ (0,01,0,04)	0.02535910	1	0.0253591	457.0790	<0.0001*
X ₂ (295,298)	0.00090258	1	0.0009026	16.2684	0.0157*
X ₃ (2,1e-8,2,9e-8)	0.00183558	1	0.0018356	33.0849	0.0045*
X ₄	0.00729494	2	0.0036475	65.7429	0.0009*
X ₁ ×X ₄	0.00067118	2	0.0003356	6.0487	0.0617
X ₂ ×X ₃	0.00065219	1	0.0006522	11.7552	0.0266*
X ₂ ×X ₄	0.00074922	2	0.0003746	6.7521	0.0522
X ₃ ×X ₄	0.00280665	2	0.0014033	25.2939	0.0054*
X ₁ ×X ₂ ×X ₄	0.00096015	2	0.0004801	8.6530	0.0352*
X ₁ ×X ₃ ×X ₄	0.00037302	2	0.0001865	3.3617	0.1391
X ₁ ×X ₂ ×X ₃	0.00042009	1	0.0004201	7.5718	0.0513
X ₁ ×X ₂ ×X ₃ ×X ₄	0,00068150	2	0.0003407	6.1418	0.0603
Residual	0,00022192	4	0.0000555	–	–
Total	0.04292811	23	–	–	–
R ²	0.99483035	–	–	–	–
Adj R ²	0.97027453	–	–	–	–

(* Signifiant selon la valeur de probabilité ≤ 0.05 , **SS** somme des carrés, **DF** degré de liberté, **MS** carré moyen).

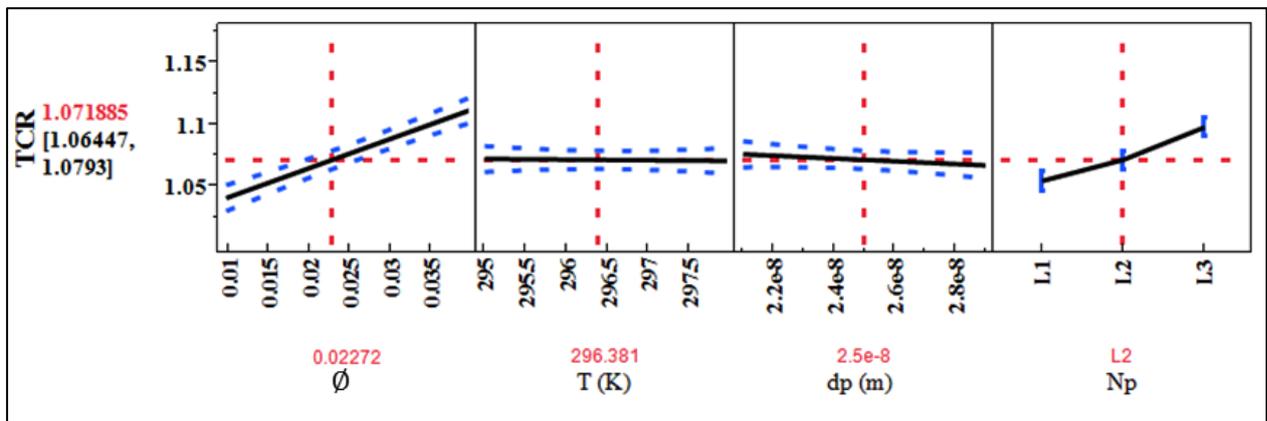


Figure III.2: Prédiction de TCR par rapport à X₁(ϕ), X₂(T), X₃(dp) et X₄ (Np).

[Lignes rouges : valeur prédite de TCR ; Lignes bleu : 95% de confiance sur la moyenne de TCR]

La figure (III.2) montre les profils de la réponse prédite TCR par rapport aux quatre facteurs: (ϕ , T, dp et Np), codés X₁, X₂, X₃ et X₄ respectivement.

Ces résultats montrent qu'il existe une corrélation entre la fraction volumique (ϕ) et la température (T) et TCR, car ces deux facteurs ont un effet positif sur la réponse. La valeur de TCR augmente linéairement et atteint des valeurs maximales quand les facteurs X₁ et X₂ sont au maximum. En revanche, le diamètre des nanoparticules (dp) a un effet négatif sur la

réponse. Cela signifie que la réponse diminue lorsque ce facteur passe du niveau bas au niveau haut. En conséquence, il peut être confirmé que CuO est la nanoparticule prééminente utilisée pour augmenter la réponse TCR.

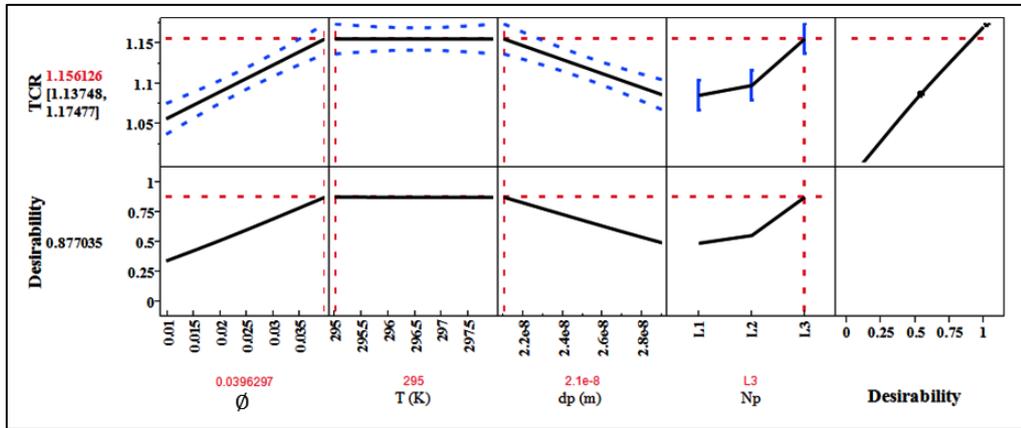


Figure III.3: Profils de prédiction aux paramètres optimaux.

La maximisation de la désirabilité est effectuée pour obtenir des paramètres de facteur optimaux pour un TCR maximum. Le profil de la figure (III.3) affiche les paramètres optimaux suivants : 0,042 pour la fraction volumique ; 294,73 k pour la température ; 21,27 nm pour le diamètre des particules et CuO pour le type de nanoparticules, donnant ainsi une réponse estimée égale à 1,162.

III.3.2 Validation du modèle proposé

Afin de valider le modèle proposé du rapport de conductivité des nanofluides (TCR), une comparaison avec des résultats expérimentaux et théoriques est effectuée. Les figures III.4-III.9 montrent les effets de différents paramètres sur le rapport de conductivité thermique de l'ensemble de données expérimentales des nanofluides (tirées de la littérature) par rapport au modèle obtenu dans notre étude.

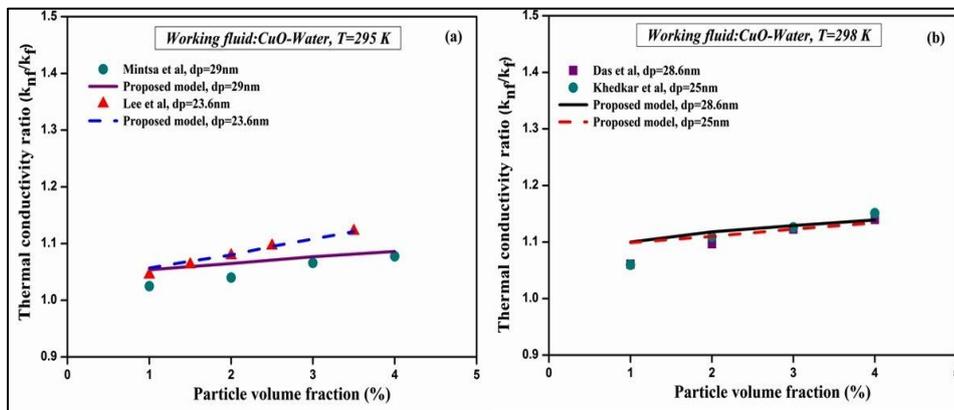


Figure III.4: Effets de la fraction volumique des nanoparticules sur TCR du nanofluide CuO/Eau par rapport au modèle proposé pour différents diamètres : (a) 295 K et (b) 298 K.

Les effets des fractions volumiques sur le TCR prédit avec différents diamètres de nanoparticules de nanofluides CuO–Eau et à des températures de 295 K et 298 K, sont donnés dans les figures III.4 (a) et (b) respectivement. Comme on peut le voir sur ces figures, le modèle proposé est en très bon accord avec les données expérimentales [31, 45, 46].

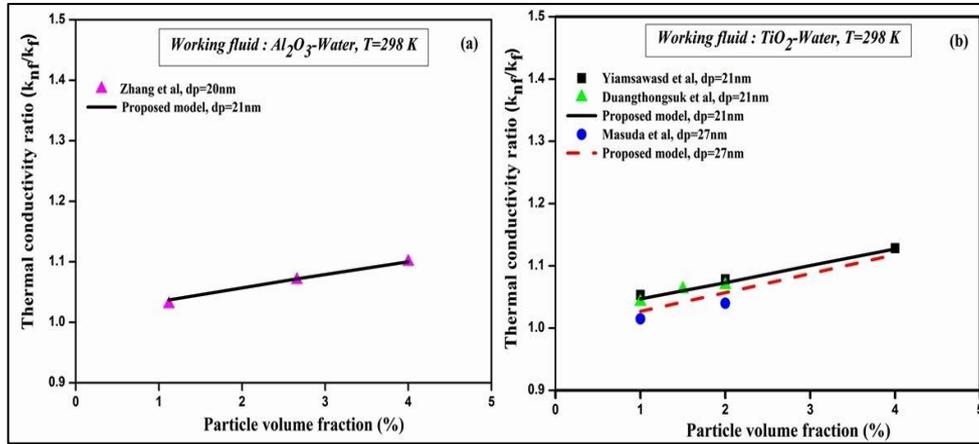


Figure III.5: Effets de la fraction volumique des nanoparticules sur TCR du nanofluides de (a) Al₂O₃/Eau et (b) TiO₂/Eau par rapport au modèle proposé pour différents diamètres.

La figure III.5 (a) montre la capacité de prédiction de TCR du modèle obtenu pour un nanofluides Al₂O₃/Eau à 298 K, comparé aux données expérimentales [32]. Ainsi, le modèle proposé dans cette étude a une prédiction précise du rapport de conductivité thermique et ceci pour différentes fractions volumiques de particules.

De même, la figure 5 (b) illustre un bon accord de TCR du nanofluides TiO₂/Eau du modèle proposé par rapport aux données expérimentales de [33, 34, 45] ; et ceci aux mêmes conditions de température, de fraction volumique et pour différents diamètres des nanoparticules.

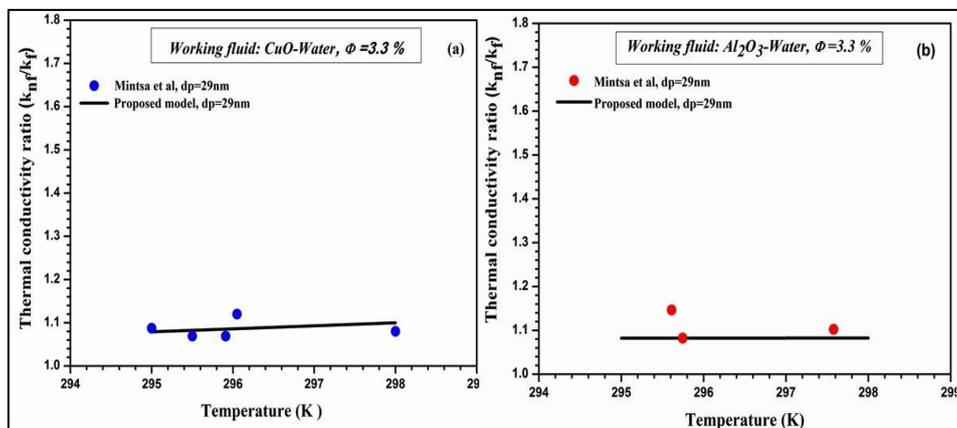


Figure III.6: Effets de la température sur TCR du nanofluides de (a) CuO-Eau and (b) Al₂O₃-Eau, par rapport au modèle proposé.

Les effets de variation de température (T) sur le rapport de conductivité thermique des nanofluides de CuO/Eau et Al_2O_3 /Eau pour des nanoparticules de diamètre de 29 nm sont présentés respectivement dans les figures III.6 (a) et III.6 (b). Les prédictions de TCR du modèle proposé sont dans une précision acceptable pour des données expérimentales disponibles [31].

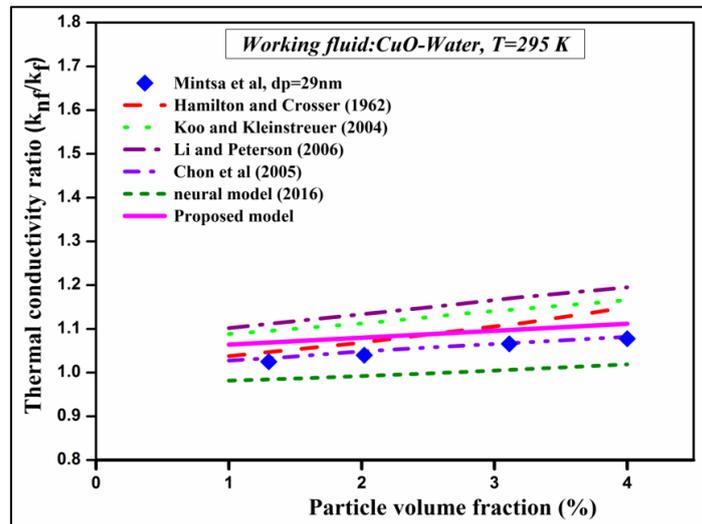


Figure III.7: Comparaison des résultats des modèles expérimentaux et théoriques de TCR de nanofluide CuO/eau avec le nouveau modèle proposé, en fonction de la fraction volumique.

La figure III.7 présente les résultats de TCR de nanofluide CuO/Eau à température ambiante de notre modèle comparés aux résultats expérimentaux de référence [31] ainsi qu'aux résultats des corrélations développées par Chon et al [47], Koo & Kleinstreuer [48], Li & Peterson [49], Hamilton–Crosser [50] ainsi que le modèle Neuronal d'Aminian [31].

Comme on peut le voir, le modèle proposé dans cette étude offre un meilleur accord avec les valeurs expérimentales que les résultats obtenus par les modèles Li et Peterson, Koo & Kleinstreuer et Neural. De même, la corrélation développée par Chon et al [47] correspond toutefois parfaitement aux données expérimentales. De plus, on remarque que la relation Hamilton–Crosser donne de bons résultats pour des petites valeurs de fraction volumique de particules.

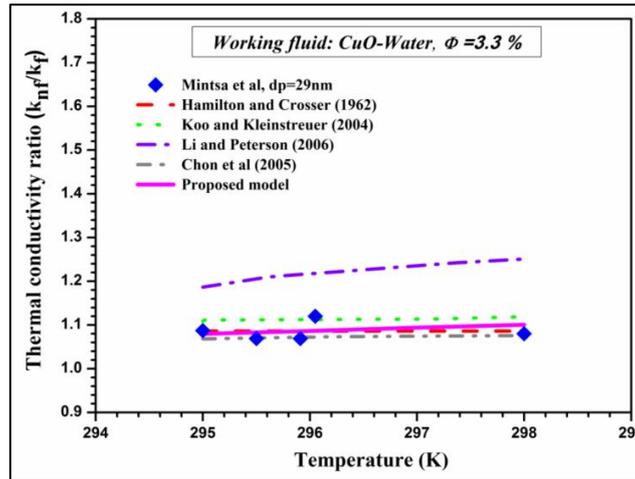


Figure III.8: Comparaison des résultats des modèles expérimentaux et théoriques de TCR de nanofluide CuO-eau avec le nouveau modèle proposé, en fonction de la température.

La variation du rapport de conductivité thermique des nanofluides en fonction de la température obtenue par notre modèle est comparée aux résultats de diverses corrélations ainsi qu'à l'ensemble de données expérimentales de Mints et al [31], et ceci pour CuO/Eau de 29 nm de diamètre et 4% de fraction volumique (figure III.8). Comme on peut le voir clairement, le modèle proposé dans notre étude présente un meilleur accord avec les données expérimentales. Néanmoins, les deux relations développées par Koo & Kleinstreuer [48] et Chon et al [47] montrent des résultats relativement bons. Par contre, le modèle de Li & Peterson [49] ne prédit pas correctement la tendance à l'amélioration de la conductivité thermique obtenue par Mints et al [31]. Il est également intéressant de noter que le modèle de Hamilton–Crosser [50] reste une prédiction acceptable de la conductivité thermique effective des nanofluides à température ambiante.

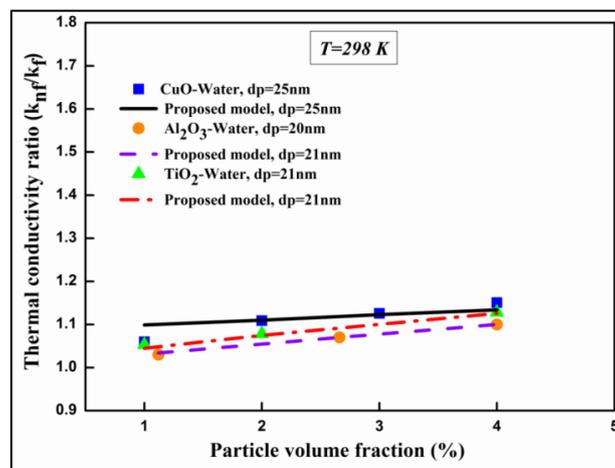


Figure III.9: Effets de la fraction volumique des nanoparticules sur le TCR des nanofluides par rapport au modèle proposé pour différentes nanoparticules.

La figure III.9 illustre une comparaison entre des valeurs expérimentales de TCR avec celles obtenue à partir de notre modèle, l'ensemble des données expérimentales utilisées dans cette figure proviennent des références [32, 34, 46]. Les résultats prédits par notre modèle sont de bonne précision et présentent une bonne corrélation par rapport aux résultats expérimentaux.

III.4 Conclusion

Dans cette étude, une approche par un plan factorielle complet a été réalisée afin d'estimer l'amélioration de la conductivité thermique des nanofluides d'Oxyde Métallique/Eau avec des nanoparticules d' Al_2O_3 , TiO_2 et CuO . Un nouveau modèle évaluant le rapport de conductivité thermique (TCR) des nanofluides Oxyde/Eau a été développé en utilisant des données expérimentales abondantes et étendues. Ce modèle est applicable dans une plage de fractions volumiques de particules de 1% à 4%, à de basses températures entre 295 K et 298 K et pour des diamètres de particules de 21 nm à 29 nm. Les facteurs affectant le rapport d'amélioration de la conductivité thermique sont identifiés et analysés par la méthode ANOVA. Ces facteurs sont : la fraction volumique, la température, le diamètre et le type des nanoparticules. Les résultats obtenus montrent que la fraction volumique des particules a l'effet le plus significatif sur l'amélioration de la conductivité thermique des nanofluides par rapport aux autres facteurs. Une augmentation de la fraction volumique et de la température des particules possède un effet favorable sur l'amélioration de la conductivité thermique des nanofluides, tandis qu'une taille de particule plus grande tend à la réduire. On constate que la fraction volumique des nanoparticules a aussi un grand impact sur les propriétés thermo-physiques des nanofluides. Ainsi, la concentration optimale de nanoparticules est essentielle pour déterminer dans la formation de nanofluides qui peut améliorer les performances des systèmes thermiques. Enfin, l'évaluation des résultats montre une excellente corrélation entre les réponses de TCR prédits et observés, indiquant une bonne concordance entre le modèle obtenu et les données expérimentales. Par ailleurs, les résultats obtenus confirment la capacité du modèle proposé dans notre étude à prédire la conductivité thermique des nanofluides avec une grande précision.

III.5 Références

- [1] Choi, S. U. (1995). Enhancing conductivity of fluids with nanoparticles. ASME Fluid Eng. Division. 231:99-105.
- [2] Nair, V., Parekh, A. D., Tailor, P. R. (2018). Water-based Al_2O_3 , CuO and TiO_2 nanofluids as secondary fluids for refrigeration systems: a thermal conductivity

- study. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 40(5), 1-17.
- [3] Karimipour, A., Bagherzadeh, S. A., Taghipour, A., Abdollahi, A., Safaei, M. R. (2019). A novel nonlinear regression model of SVR as a substitute for ANN to predict conductivity of MWCNT-CuO/water hybrid nanofluid based on empirical data. *Physica A: Statistical Mechanics and its Applications*, 521, 89-97.
- [4] Ghasemi, A., Hassani, M., Goodarzi, M., Afrand, M., Manafi, S. (2019). Appraising influence of COOH-MWCNTs on thermal conductivity of antifreeze using curve fitting and neural network. *Physica A: Statistical Mechanics and its Applications*, 514, 36-45.
- [5] Alrashed, A. A., Gharibdousti, M. S., Goodarzi, M., de Oliveira, L. R., Safaei, M. R., Bandarra Filho, E. P. (2018). Effects on thermophysical properties of carbon based nanofluids: experimental data, modelling using regression, ANFIS and ANN. *International Journal of Heat and Mass Transfer*, 125, 920-932.
- [6] Amani, M., Amani, P., Kasaeian, A., Mahian, O., Wongwises, S. (2017). Thermal conductivity measurement of spinel-type ferrite MnFe₂O₄ nanofluids in the presence of a uniform magnetic field. *Journal of Molecular Liquids*, 230, 121-128.
- [7] Amani, M., Amani, P., Kasaeian, A., Mahian, O., Pop, I., Wongwises, S. (2017). Modeling and optimization of thermal conductivity and viscosity of MnFe₂O₄ nanofluid under magnetic field using an ANN. *Scientific reports*, 7(1), 1-13.
- [8] Ahmadi, M. H., Nazari, M. A., Ghasempour, R., Madah, H., Shafii, M. B., Ahmadi, M. A. (2018). Thermal conductivity ratio prediction of Al₂O₃/water nanofluid by applying connectionist methods. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 541, 154-164.
- [9] Hosseini, S. M., Safaei, M. R., Goodarzi, M., Alrashed, A. A., Nguyen, T. K. (2017). New temperature, interfacial shell dependent dimensionless model for thermal conductivity of nanofluids. *International Journal of Heat and Mass Transfer*, 114, 207-210.
- [10] Esfahani, M. A., Toghraie, D. (2017). Experimental investigation for developing a new model for the thermal conductivity of silica/water-ethylene glycol (40%–60%) nanofluid at different temperatures and solid volume fractions. *Journal of Molecular Liquids*, 232, 105-112.

- [11] Cabaleiro, D., Gracia-Fernández, C., Legido, J. L., Lugo, L. (2015). Specific heat of metal oxide nanofluids at high concentrations for heat transfer. *International journal of heat and mass transfer*, 88, 872-879.
- [12] Mahian, O., Kianifar, A., Heris, S. Z., Wongwises, S. (2016). Natural convection of silica nanofluids in square and triangular enclosures: theoretical and experimental study. *International Journal of Heat and Mass Transfer*, 99, 792-804.
- [13] Goshayeshi, H. R., Safaei, M. R., Goodarzi, M., Dahari, M. (2016). Particle size and type effects on heat transfer enhancement of Ferro-nanofluids in a pulsating heat pipe. *Powder Technology*, 301, 1218-1226.
- [14] Khairul, M. A., Shah, K., Doroodchi, E., Azizian, R., Moghtaderi, B. (2016). Effects of surfactant on stability and thermo-physical properties of metal oxide nanofluids. *International Journal of Heat and Mass Transfer*, 98, 778-787.
- [15] Esfe, M. H., Saedodin, S., Bahiraei, M., Toghraie, D., Mahian, O., Wongwises, S. (2014). Thermal conductivity modeling of MgO/EG nanofluids using experimental data and artificial neural network. *Journal of Thermal Analysis and Calorimetry*, 118(1), 287-294.
- [16] Sheikholeslami, M., Bhatti, M. M. (2017). Forced convection of nanofluid in presence of constant magnetic field considering shape effects of nanoparticles. *International Journal of Heat and Mass Transfer*, 111, 1039-1049.
- [17] Qi, C., Wang, G., Yang, L., Wan, Y., Rao, Z. (2017). Two-phase lattice Boltzmann simulation of the effects of base fluid and nanoparticle size on natural convection heat transfer of nanofluid. *International Journal of Heat and Mass Transfer*, 105, 664-672.
- [18] Amanuel, T., Mishra, M. (2018). Investigation of thermohydraulic performance of triple concentric-tube heat exchanger with CuO/water nanofluid: Numerical approach. *Heat Transfer—Asian Research*, 47(8), 974-995.
- [19] Esfe, M. H., Hajmohammad, H., Toghraie, D., Rostamian, H., Mahian, O., Wongwises, S. (2017). Multi-objective optimization of nanofluid flow in double tube heat exchangers for applications in energy systems. *Energy*, 137, 160-171.
- [20] Mahian, O., Kolsi, L., Amani, M., Estellé, P., Ahmadi, G., Kleinstreuer, C., ... Pop, I. (2019). Recent advances in modeling and simulation of nanofluid flows-Part I: Fundamentals and theory. *Physics reports*, 790, 1-48.
- [21] Goodarzi, M., Toghraie, D., Reiszadeh, M., Afrand, M. (2019). Experimental evaluation of dynamic viscosity of ZnO–MWCNTs/engine oil hybrid nanolubricant

- based on changes in temperature and concentration. *Journal of Thermal Analysis and Calorimetry*, 136(2), 513-525.
- [22] Abdollahi, A., Darvanjooghi, M. H. K., Karimipour, A., Safaei, M. R. (2018). Experimental study to obtain the viscosity of CuO-loaded nanofluid: effects of nanoparticles' mass fraction, temperature and basefluid's types to develop a correlation. *Meccanica*, 53(15), 3739-3757.
- [23] Bahrami, M., Akbari, M., Bagherzadeh, S. A., Karimipour, A., Afrand, M., Goodarzi, M. (2019). Develop 24 dissimilar ANNs by suitable architectures & training algorithms via sensitivity analysis to better statistical presentation: Measure MSEs between targets & ANN for Fe–CuO/Eg–Water nanofluid. *Physica A: Statistical Mechanics and Its Applications*, 519, 159-168.
- [24] Shen, M., Dai, Y., Chen, H. (2018). Nonsimilarity boundary layer flow of copper–water nanofluid near stagnation point in a porous medium. *Heat Transfer—Asian Research*, 47(2), 389-403.
- [25] Yiamsawas, T., Dalkilic, A. S., Mahian, O., Wongwises, S. (2013). Measurement and correlation of the viscosity of water-based Al₂O₃ and TiO₂ nanofluids in high temperatures and comparisons with literature reports. *Journal of dispersion science and technology*, 34(12), 1697-1703.
- [26] Pramuanjaroenkij, A., Tongkratoke, A., Kakaç, S. J. J. O. E. P. (2018). Numerical study of mixing thermal conductivity models for nanofluid heat transfer enhancement. *Journal of Engineering Physics and Thermophysics*, 91(1), 104-114.
- [27] Phan, N. M., Bui, H. T., Nguyen, M. H., Phan, H. K. (2014). Carbon-nanotube-based liquids: a new class of nanomaterials and their applications. *Advances in Natural Sciences: Nanoscience and Nanotechnology*, 5(1), 015014.
- [28] Rashmi, W., Khalid, M., Ong, S. S., Saidur, R. (2014). Preparation, thermo-physical properties and heat transfer enhancement of nanofluids. *Materials Research Express*, 1(3), 032001.
- [29] Dasgupta, D., Mondal, K. (2017). Thermal circuits based model for predicting the thermal conductivity of nanofluids. *International Journal of Heat and Mass Transfer*, 113, 806-818.
- [30] Alawi, O. A., Sidik, N. A. C., Xian, H. W., Kean, T. H., Kazi, S. N. (2018). Thermal conductivity and viscosity models of metallic oxides nanofluids. *International Journal of Heat and Mass Transfer*, 116, 1314-1325.

- [31] Aminian, A. (2016). Predicting the effective thermal conductivity of nanofluids for intensification of heat transfer using artificial neural network. *Powder Technology*, 301, 288-309.
- [32] Kazemi-Beydokhti, A., Heris, S. Z., Moghadam, N., Shariati-Niasar, M., Hamidi, A. A. (2014). Experimental investigation of parameters affecting nanofluid effective thermal conductivity. *Chemical Engineering Communications*, 201(5), 593-611.
- [33] Duangthongsuk, W., Wongwises, S. (2009). Heat transfer enhancement and pressure drop characteristics of TiO₂-water nanofluid in a double-tube counter flow heat exchanger. *International Journal of Heat and Mass Transfer*, 52(7-8), 2059-2067.
- [34] Yiamsawasd, T., Dalkilic, A. S., Wongwises, S. (2012). Measurement of the thermal conductivity of titania and alumina nanofluids. *Thermochimica Acta*, 545, 48-56.
- [35] Longo, G. A., Zilio, C., Ortombina, L., Zigliotto, M. (2017). Application of Artificial Neural Network (ANN) for modeling oxide-based nanofluids dynamic viscosity. *International Communications in Heat and Mass Transfer*, 83, 8-14.
- [36] Salman, S. D. (2019). Comparative study on heat transfer enhancement of nanofluids flow in ribs tube using CFD simulation. *Heat Transfer—Asian Research*, 48(1), 148-163.
- [37] Nazari, S., Akbari, E. (2019). Numerical investigation of non-Newtonian nanofluid mixed convection in a two-opposite direction lid-driven cavity with variable properties. *Heat Transfer—Asian Research*, 48(2), 601-623.
- [38] Mebarek-Oudina, F. (2019). Convective heat transfer of Titania nanofluids of different base fluids in cylindrical annulus with discrete heat source. *Heat Transfer—Asian Research*, 48(1), 135-147.
- [39] Ben Hamida, M. B., Charrada, K. (2015). Natural convection heat transfer in an enclosure filled with an ethylene glycol—copper nanofluid under magnetic fields. *Numerical Heat Transfer, Part A: Applications*, 67(8), 902-920.
- [40] Marcus Y. *The properties of solvents*. New York: John Wiley & Sons; 1998.
- [41] Bounouri, Y., Berkani, M., Zamouche, A., Rycerz, L. (2020). Optimization and modeling of synthesis parameters of neodymium (III) bromide by dry method using full factorial design analysis. *Arabian Journal of Chemistry*, 13(1), 366-376.
- [42] Barka, N., Abdennouri, M., Boussaoud, A., Galadi, A., Baâlala, M., Bensitel, M., ... Sadiq, M. (2014). Full factorial experimental design applied to oxalic acid

- photocatalytic degradation in TiO₂ aqueous suspension. *Arabian Journal of Chemistry*, 7(5), 752-757.
- [43] Barari, F., Morgan, R., Barnard, P. (2014, November). A Design of Experiments (DOE) approach to optimise temperature measurement accuracy in Solid Oxide Fuel Cell (SOFC). In *Journal of Physics: Conference Series* (Vol. 547, No. 1, p. 012004). IOP Publishing.
- [44] Kumar, L., Reddy, M. S., Managuli, R. S., Pai, G. (2015). Full factorial design for optimization, development and validation of HPLC method to determine valsartan in nanoparticles. *Saudi Pharmaceutical Journal*, 23(5), 549-555.
- [45] Zerradi, H., Ouaskit, S., Dezairi, A., Loulijat, H., & Mizani, S. (2014). New Nusselt number correlations to predict the thermal conductivity of nanofluids. *Advanced Powder Technology*, 25(3), 1124-1131.
- [46] Khedkar, R. S., Sonawane, S. S., Wasewar, K. L. (2012). Influence of CuO nanoparticles in enhancing the thermal conductivity of water and monoethylene glycol based nanofluids. *International Communications in Heat and Mass Transfer*, 39(5), 665-669.
- [47] Chon, C. H., Kihm, K. D., Lee, S. P., Choi, S. U. (2005). Empirical correlation finding the role of temperature and particle size for nanofluid (Al₂O₃) thermal conductivity enhancement. *Applied Physics Letters*, 87(15), 153107.
- [48] Koo, J., Kleinstreuer, C. (2004). A new thermal conductivity model for nanofluids. *Journal of Nanoparticle research*, 6(6), 577-588.
- [49] Li, C. H., Peterson, G. P. (2006). Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids). *Journal of Applied Physics*, 99(8), 084314.
- [50] Hamilton, R. L., Crosser, O. K. (1962). Thermal conductivity of heterogeneous two-component systems. *Industrial & Engineering chemistry fundamentals*, 1(3), 187-191.

The background features a minimalist design with three green circles of varying sizes and two thin green lines. One line starts from the top left and ends near the middle of the smaller circle. Another line starts from the top right and ends near the bottom of the largest circle. The circles have a slight gradient and a soft shadow.

Chapitre IV

IV.1 Introduction

Comme nous l'avons vu auparavant, plusieurs paramètres peuvent jouer un rôle dans l'efficacité des nanofluides comme la concentration, le type ainsi que la forme des nanoparticules, les propriétés du fluide de base, la température, etc. La majorité des études sur les propriétés des nanofluides ont accordé une attention particulière à ces propriétés, en particulier en ce qui concerne l'influence de la viscosité dynamique et de la conductivité thermique sur la capacité de transfert de chaleur [1].

De nombreuses analyses expérimentales [2–6] et théoriques [7–11] des propriétés thermophysiques des nanofluides ont été menées par de nombreux scientifiques. En général, la température et la fraction volumique sont considérées comme des facteurs importants dans le développement des modèles de calcul des propriétés thermophysiques, en particulier pour le calcul de la conductivité thermique et la viscosité [12–15]. L'augmentation de la température conduit à une augmentation de conductivité thermique et une réduction de la viscosité dynamique; tandis qu'une concentration plus élevée en phase solide entraîne une augmentation à la fois de la conductivité thermique et de la viscosité dynamique.

Outre la température et la fraction volumique, d'autres paramètres tels que la forme et le type de particules ainsi que le rapport de mélange influencent également les propriétés thermophysiques des nanofluides. La valeur précise de ces dernières sous divers paramètres ne peut pas être prédite facilement. De plus, en termes de modèles de suspensions particules-liquides classiques, le mécanisme de transport de chaleur pour les nanofluides est difficile à comprendre.

Actuellement, la plupart des modèles disponibles sont applicables aux nanofluides avec une concentration plus faible de nanoparticules (de 0,01 à 0,5% en volume) et une dispersion uniforme. Cependant, ces modèles ne présentent pas de corrélation entre les propriétés thermophysiques et la forme des nanoparticules. En plus, la mesure des propriétés thermophysiques des nanofluides pour une température, une concentration, une taille et une forme spécifiques nécessite beaucoup de temps, d'énormes données et d'argent. Afin de surmonter ces problèmes, de nombreux chercheurs ont suggéré différentes formes de calcul ou de modèles empiriques pour la prédiction des propriétés thermophysiques de ces nanofluides. Et le moyen le plus simple et le plus efficace pour déterminer ces propriétés pour divers nanofluides est l'utilisation des approches informatiques douces telles que les Réseaux de neurones artificiels (RNA) [16].

De ce fait, on constate que la majorité des travaux de recherches montrent que les paramètres et mécanismes affectant la conductivité thermique des nanofluides ne peuvent pas être pris en compte simultanément par des modèles traditionnels de suspensions de particules [17]. En conséquence, plusieurs nouveaux modèles utilisant des Réseaux de Neurones Artificiels Améliorés

RNAA (EANN) ainsi que des approches Adaptatives du Système d'Inférence Neuro-Floue (ANFIS) ont été proposés ; comme les travaux d'Alrashed et *al.* [18, 19] qui donnent des résultats d'une précision appropriée. Tandis-que Hosseini et *al.* [20] ont présenté un modèle de conductivité thermique des nanofluides en fonction de la conductivité thermique des nanoparticules prenant en compte le fluide de base, la température, la fraction volumique, la taille des nanoparticules ainsi que les propriétés de l'enveloppe inter-faciale et leurs résultats montrant une bonne compatibilité avec les données expérimentales ainsi qu'avec d'autres modèles. Shahsavar et *al.* [21] qu'ont à eux, ont exploré plusieurs expériences avec la méthode des Réseaux de Neurones Artificiels (RNA) afin de modéliser la conductivité thermique ainsi que la viscosité des nanofluides. Bagherzadeh et *al.* [22] ont développé l'approche améliorée EANN pour le calcul de la conductivité thermique des nanofluides, et les résultats obtenus étaient conforme et ceci en utilisant moins de temps de calcul.

Sadeghi et *al.* [23] ont utilisé la technique RNA pour vérifier les résultats expérimentaux des caractéristiques thermiques (énergie et exergie) du nanofluide Oxyde de Cuivre/Eau dans un capteur solaire à tube sous vide et ceci via les méthodes de perceptron multicouche (MLP) et en fonction de la base radiale (RBF). Les auteurs ont observé que le taux d'erreur maximal des modèles MLP était inférieur à celui du modèle RBF. Les études numériques (par approche Eulérienne à deux phases), avec la technique RNA (algorithme d'apprentissage de rétro-propagation de Levenberg–Marquardt), et expérimentales de Naphon et *al.* [24], montrent que l'écart moyen des caractéristiques thermiques des nanofluides de Titane/Eau dé-ionisée obtenu entre les données calculées et prévues était de 1,25% dans tous les cas.

Par conséquent, dans ce chapitre, une modélisation par la méthode des Réseaux Neuronaux Artificiels est utilisée pour prédire et évaluer la conductivité thermique effective et la viscosité dynamique des nanofluides Al₂O₃/Eau.

IV.2 Réseaux de Neurones Artificiels

La procédure de fonctionnement des réseaux de neurones artificiels est brièvement expliquée ci-dessous.

Un réseau neuronal artificiel est une approche prédictive précise et puissante qui s'applique à la modélisation des systèmes d'ingénierie et à la reconnaissance des modèles. Un avantage majeur de l'utilisation des réseaux de neurones est que ce modèle peut simplement apprendre la relation entre les variables d'entrée et de sortie. Les modèles de réseaux neuronaux se révèlent extrêmement précis dans des applications telles que le contrôle de processus, la modélisation, la simulation et l'identification de système [25].

En outre, la technique RNA a été largement utilisée pour prédire les systèmes non linéaires en raison des avantages notables qui sont la haute précision, les faibles coûts et temps [26].

Des études récentes montrent que les modèles de prédiction de la conductivité thermique effective et la viscosité dynamique des nanofluides par réseau de neurone et plus particulièrement le Perceptron Multicouches (MLP), qui est un type de réseaux de neurones à fort potentiel prédictif, donnent de très bonnes performances [27-32].

IV.2.1 Type de modèle RNA

Les réseaux de neurones MLP (*Perceptron multicouches* ou en anglais *the multilayer perceptron*) sont des réseaux artificiels de type "feed-forward", c'est-à-dire à propagation directe. Une architecture de réseau de neurones largement utilisée dans le domaine des approches de données pilotées. Les réseaux de neurones MLP sont capable de créer un mappage entre les données d'entrée et de sortie via un algorithme d'apprentissage pour réduire l'erreur entre la sortie réelle et la sortie réseau [29, 31].

Dans cette étude, un réseau MLP est adopté pour prédire la conductivité thermique et la viscosité du nanofluide d'Alumine/ Eau. Les neurones sont groupés en couches, la première et la dernière sont appelées respectivement *couche d'entrée* et *couche de sortie*. Entre ces deux couches il peut exister une ou plusieurs couches appelées *couches cachées* comme le montre la figure (IV.1) [33].

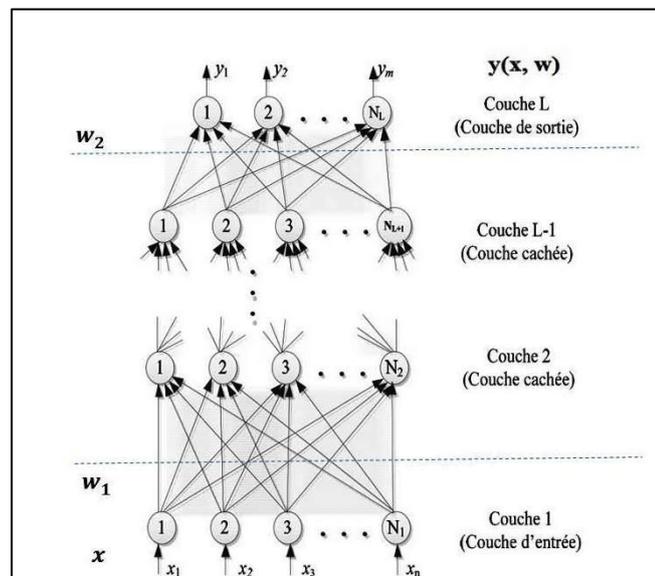


Figure IV.1: Architecture d'une structure neuronale MLP

Avec :

L est le nombre total de couches, la première est la couche d'entrée, la L^{ieme} est la couche de sortie, les couches de 2 à $L - 1$ représentent les couches cachées, N_l est le nombre de neurone dans la l^{ieme} couche avec $l = 1, 2, \dots, L$. w_{ij}^l représente le coefficient synaptique de la connexion reliant le neurone j de la couche $l - 1$ au neurone i de la l^{ieme} couche, le coefficient w_{i0}^l représente le biais ou le seuil du neurone i de la l^{ieme} couche. x_i est la i^{ieme} entrée du réseau, z_i^l est la sortie du neurone i de la couche l et enfin y_i est la i^{ieme} sortie du réseau. Avec $j = 0, 1, \dots, N_{l-1}$, $i = 0, 1, \dots, N_l$.

La sortie $y(x, w)$ est une fonction non linéaire du vecteur des variables x , de composantes x_1, x_2, \dots, x_n et du vecteur des paramètres w , dont les composantes sont les $(n) N_l + N_L$ paramètres du réseau.

$$y = y(x, w) = g \left\{ w_{N_L,0} + \sum_{i=1}^{N_L} \left[w_{N_L,i} f \left(w_{i0}^l + \sum_{j=1}^{N_{l-1}} w_{ij}^l x_j \right) \right] \right\} \quad (IV.1)$$

Avec $w_{N_L,0}$ et w_{i0}^l qui sont les biais attribués respectivement à la couche de sortie et à la couche masquée. $w_{N_L,i}$ et w_{ij}^l désigne la matrice de pondération liant le calque masqué au calque de sortie et l'entrée au calque masqué, et $f(.)$ représente la fonction d'excitation (activation) [34].

Nous adoptons la forme du MLP de la figure (IV. 1), contenant une seule couche cachée et ayant la fonction sigmoïde comme fonction d'activation donné par l'équation (IV.2) et la fonction linéaire comme fonction d'activation de la couche de sortie donné par l'équation (IV.3).

$$f(x) = \frac{1}{1+e^{-x}} \quad (IV.2)$$

$$g(x) = x \quad (IV.3)$$

IV.2.2 Procédure d'apprentissage de réseaux de neurones artificiels

Le processus d'apprentissage est une procédure bien établie qui tente d'ajuster les paramètres de modèle RNA, c'est-à-dire les biais et les poids de connexion. Au cours du processus d'apprentissage, le modèle RNA est doté d'un nombre suffisant de données expérimentales contenant à la fois des variables indépendantes et dépendantes des phénomènes considérés.

Ensuite, un algorithme d'apprentissage approprié est utilisé pour ajuster les paramètres du modèle RNA de manière à pouvoir prédire les cibles réelles avec une précision acceptable. La phase de formation commence avec des valeurs aléatoires pour les poids et les biais du modèle RNA. Par la suite, les signaux numériques de variable (s) indépendante (s) sont envoyés au réseau artificiel et sont amenés à le traverser jusqu'à ce qu'ils atteignent la couche de sortie. Enfin, la couche de sortie est responsable de la production du ou des signaux de sortie. Un algorithme d'apprentissage est

ensuite appliqué pour minimiser la différence entre les valeurs réelles et calculées pour la ou les variables dépendantes en régulant les paramètres du modèle RNA. Cet ajustement se poursuit jusqu'à ce que l'écart entre les valeurs cibles calculées et réelles atteigne la tolérance prédéfinie. Dès que la phase de formation est terminée, les poids et les biais sont ajustés et restent inchangés. A ce stade, il est possible d'utiliser l'approche RNA entraînée pour estimer la ou les variables dépendantes à partir de nouveaux ensembles de données indépendants [1].

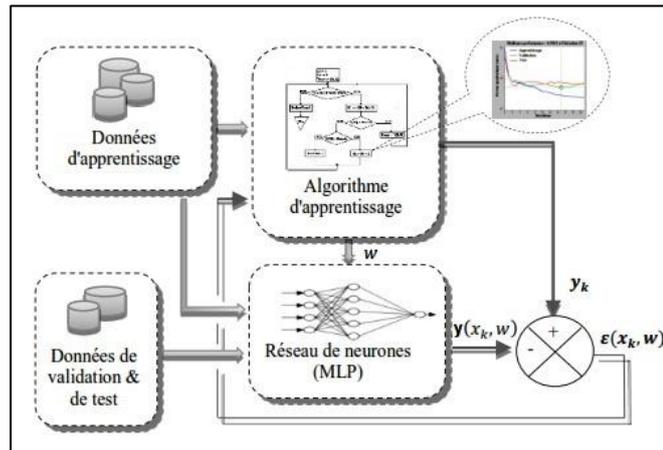


Figure IV.2: Schéma bloc de l'apprentissage d'un réseau de neurones

IV.3 Méthodologie

IV.3.1 Données expérimentales

Dans cette étude, une structure de réseau avec une couche cachée est utilisée pour prédire la conductivité thermique et la viscosité du nanofluide (figure IV.3). La fraction volumique, la température, le diamètre et la forme des nanoparticules sont saisis en tant que paramètres indépendants (Entrées), le rapport de conductivité thermique (k_{nf}/k_f) et le rapport de viscosité (μ_{nf}/μ_f) sont considérés comme des paramètres dépendants (Sorties). La Gamme de ces paramètres est représentée dans le tableau IV. 1.

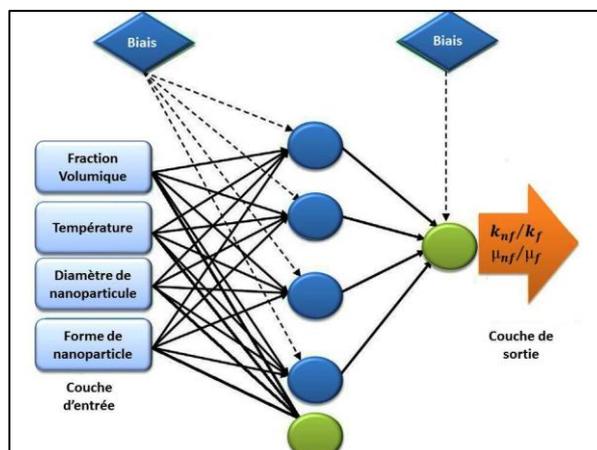


Figure IV. 3: Structure de réseau de neurone utilisé dans cette étude

Pour développer le modèle RNA, 210 valeurs de données expérimentales de conductivités thermiques effectives et de viscosités du nanofluide Al₂O₃/Eau obtenues à partir de la littérature [35] sont utilisées pour concevoir et valider les performances du modèle prédictif. Les détails des données ainsi que les propriétés thermophysiques de nanoparticule et du nanofluide utilisés dans cette étude sont présentés dans les tableaux 1, 2, 3, 4 et 5 respectivement dans l'annexe B.

Tableau IV.1: Gammes de paramètres pour le nanofluide Al₂O₃ / Eau

Paramètres	Gamme
x_1 : Fraction Volumique (%)	1-5
x_2 : Température (K)	300-320
x_3 : Diamètre de nanoparticule (nm)	20-100
x_4 : Forme de nanoparticule	Lame / plaquette / cylindrique / brique / sphérique

IV.3.2 Développement du modèle RNA

La méthodologie du présent travail a commencé avec les données collectées à partir des résultats expérimentaux menés dans l'étude précédente [35]. Les données ainsi collectées ont été analysées puis les entrées et sorties ont été sélectionnées en conséquence. Les paramètres tels que la température, la concentration, la taille et la forme des nanoparticules ont été sélectionnés comme entrées, tandis que les propriétés thermophysiques telles que la conductivité thermique et la viscosité ont été considérées comme des sorties pour le développement du réseau neuronal.

L'ensemble de données récupérées ont été subdivisées en deux ensembles, 70% pour l'apprentissage et 30% pour la validation. L'ensemble de données de validation à 30%, représentant 30 points de données sélectionnées au hasard n'a pas été utilisé dans le processus de formation, mais a été utilisé comme un validateur externe.

Les modèles RNA proposés ont été ajustés par l'algorithme de *Levenberg–Marquardt* (LM) dans la phase d'apprentissage, en utilisant les ensembles de données d'apprentissage divisés, ensuite les modèles ont été testés et validés.

Dans le présent travail, le logiciel *MATLAB R2015b* a été utilisé pour le développement des modèles. L'algorithme LM est sélectionné pour obtenir la valeur maximale du coefficient de détermination (R^2). Les modèles proposés sont formés par des algorithmes sélectionnés pour les moindres erreurs possibles [16]. L'algorithme LM a donné une meilleure précision et est décrit comme un processus itératif qui localise la plus petite fonction multivariée énoncée.

Pour évaluer les performances de notre modèle, nous avons adopté les indicateurs statistiques les plus utilisés dans la littérature, résumés dans le tableau IV. 2

Tableau IV.2: Indicateur d'évaluation des modèles

Désignation	Equation
L'erreur absolue moyenne (<i>Mean Absolute Error</i>)	$MAE = \frac{1}{N} \sum_{i=1}^N y_i - \hat{y}_i $
Erreur quadratique moyenne (<i>Mean Square Error</i>)	$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$
Somme de l'erreur quadratique (<i>Sum of Squared Error</i>)	$SSE = \sum_{i=1}^N (y_i - \hat{y}_i)^2$
Racine carrée de l'erreur quadratique Moyenne (<i>Root Mean Square Error</i>)	$RMSE = \left\{ \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \right\}^{0.5}$
Le coefficient de détermination (<i>coefficient of determination</i>)	$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$
L'écart relatif moyen absolu (<i>Absolute Average Relative Deviation</i>)	$AARD \% = \frac{1}{100} \sum_{i=1}^N \left \frac{(y_i - \hat{y}_i)}{y_i} \right $

Où N est le nombre de données expérimentales, y_i est la valeur prédite, \hat{y}_i est la valeur actuelle et \bar{y} est la moyenne des valeurs actuelles.

Note :

La *MAE* est utilisée pour mesurer l'écart entre les prédictions et les mesures.

La *RMSE* représente la moyenne des carrés des résidus.

Rappelons que la réduction de la *MAE* améliore en moyenne la prédiction, alors que la réduction de la *RMSE* signifie plutôt de limiter les grosses erreurs de prédiction.

IV.3.3 Choix de l'algorithme d'apprentissage

L'apprentissage est une étape importante de la prédiction, elle consiste à trouver des valeurs adéquates des poids et des biais suivant les conditions initiales choisies.

Nous adoptons dans cette étude l'algorithme d'apprentissage de *Levenberg Marquardt* (LM), qui permet d'obtenir une solution numérique au problème de minimisation d'une fonction souvent non linéaire et dépendante de plusieurs variables ; Cet algorithme utilise une méthode dite de second ordre consistant à évaluer le gradient de la fonction de coût et de son second dérivé.

L'algorithme de LM est un standard pour l'optimisation de l'erreur quadratique, connu par ses propriétés de convergence rapide pour les problèmes d'approximation de la « fonction de coût ». Cet algorithme favori, est surtout évident si un apprentissage très exact est exigé [36-40].

Pour approximer une fonction non linéaire par un perceptron multicouche, le choix de l'algorithme d'apprentissage est crucial. Dans cette application nous avons écrit un programme en langage Matlab basé sur l'algorithme itératif de *retro-propagation*. Notre choix s'est établi après plusieurs tests sur l'algorithme du deuxième ordre de LM, vue le temps d'apprentissage très long du

modèle itératif que nous avons développé et la précision des résultats obtenus en utilisant l'algorithme de *Levenberg Marquardt* [33].

L'algorithme optimal pour le développement de l'architecture du Réseau Neuronal Artificiel est décrit dans l'organigramme de la Figure IV.4.

Nous avons développé un algorithme qui fait varier le nombre de neurones de la couche cachée pendant un nombre d'itérations paramétrable. Le modèle retenu est le premier atteignant une erreur quadratique acceptable ou minimale.

Dans ce but, l'apprentissage a été lancé en normalisant l'ensemble complet de données. L'ensemble de données est ensuite divisé en paramètres d'entrée et de sortie (target). La fonction d'activation, l'algorithme d'apprentissage et le nombre de couches cachées ont été ainsi sélectionnés. Le nombre de deux neurones dans la couche cachée est sélectionné pour initialiser la formation du réseau. Le nombre de neurones dans la couche cachée est régulièrement augmenté de cinq à chaque répétition d'apprentissage.

Le nombre optimal de neurones dans la couche cachée est atteints, lorsque le coefficient de corrélation est au maximum et l'erreur quadratique moyenne est au minimum [29].

L'ensemble de données ainsi obtenu est ensuite comparé à l'ensemble de données expérimentales pour obtenir le meilleur ajustement global. L'architecture ainsi obtenue est acceptée comme étant le meilleur fournisseur de performances.

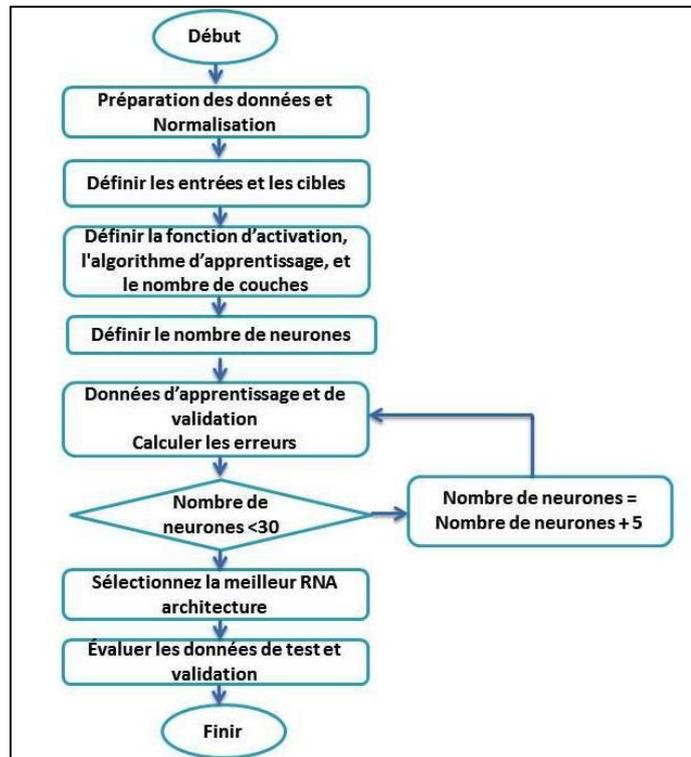


Figure IV.4: Algorithme de réseau neuronal utilisé dans ce travail

IV.4 Résultats et discussion

IV.4.1 Estimation de la conductivité thermique basée sur le RNA

Un réseau de neurone artificiel RNA a été développé sur la base des données expérimentales de la littérature disponible. Ces données expérimentales ont été divisées en deux groupes comme indiqué précédemment. Pour l'apprentissage 70% des données sont prises et 30% ont été utilisés pour les tests et validations.

L'évaluation des modèles a été réalisée en utilisant à la fois les illustrations statistiques et graphiques. La méthode d'essai et d'erreur était effectuée pour sélectionner les meilleures valeurs pour le nombre de neurones et de couches cachées. Différents nombres de couches et de neurones ont été vérifiés et leurs métriques statistiques ont été déterminées. Il a été constaté que le réseau avec une (01) couche cachée a donné les meilleurs résultats souhaités. Les valeurs de l'erreur absolue moyenne (MAE), l'erreur quadratique moyenne (MSE), la somme de l'erreur quadratique (SSE), la racine carrée de l'erreur quadratique moyenne (RMSE) et le coefficient de détermination (R^2) pour l'apprentissage et la validation sont présentés dans le tableau IV.3 et schématisés dans la figure IV. 5.

Les valeurs MSE, MAE, SSE, RMSE et R^2 observées par le modèle MLP à différents nombres de neurones cachés pour l'ensemble global de données (entraînement + validation) sont affichées dans la figure (IV. 5). On remarque que chacun des MSE, MAE, SSE, RMSE prend sa valeur minimale à 15 neurones, contrairement à R^2 qui prend sa valeur maximale au même nombre de neurones. Cela signifie que le nombre optimal de neurones dans la couche cachée est de 15.

Tableau IV.3: Évaluation des performances du réseau de neurones MLP pour les échantillons d'apprentissage et de test pour TCR.

Indicateur	Nombre de Neurones									
	Apprentissage					Test				
	5	10	15	20	25	5	10	15	20	25
MAE	9,22E-03	2,32E-02	2,46E-03	9,62E-03	1,50E-02	1,61E-02	3,17E-02	3,12E-03	1,26E-02	1,94E-02
MSE	5,99E-04	9,45E-04	1,18E-05	6,78E-04	5,03E-04	1,98E-03	2,11E-03	1,62E-05	1,78E-03	2,22E-03
SSE	4,50E-02	7,09E-02	8,82E-04	5,09E-02	3,77E-02	4,94E-02	5,28E-02	4,05E-04	4,45E-02	5,55E-02
RMSE	2,45E-02	3,07E-02	3,44E-03	2,60E-02	2,24E-02	4,45E-02	4,59E-02	4,02E-03	4,22E-02	4,71E-02
R^2	9,30E-01	8,82E-01	9,99E-01	9,19E-01	9,48E-01	9,30E-01	8,82E-01	9,99E-01	9,19E-01	9,48E-01

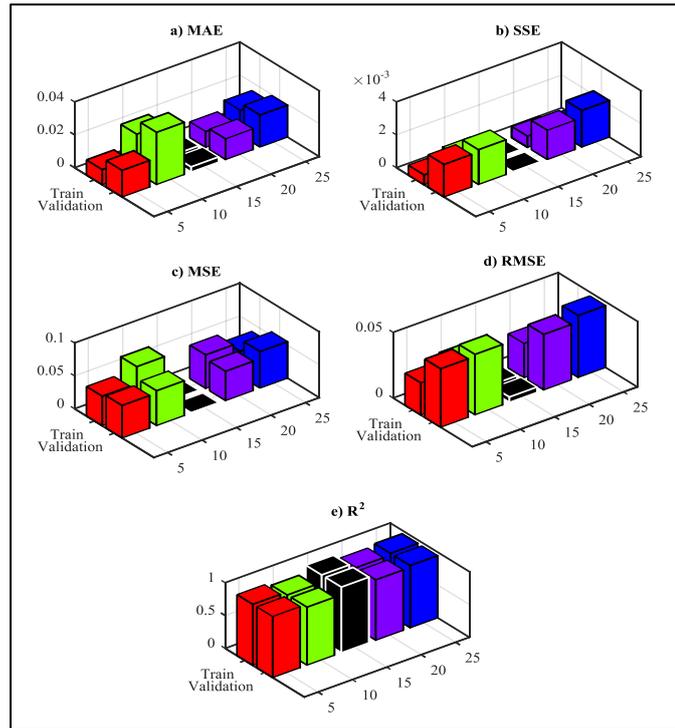


Figure IV.5: Comparaison statistique

Il peut être compris à partir du tableau IV. 3 que les performances prédictives du MLP pour le sous-ensemble d'entraînement sont améliorées et ceci en augmentant le nombre de neurones cachés. Toutefois, les performances de l'approche MLP pour l'estimation de l'ensemble de données de test ne s'améliorent qu'à 15 neurones cachés et par la suite aucun progrès évident n'est observé. On peut conclure que l'augmentation des neurones cachés de plus de 15 ne fait qu'agrandir les réseaux MLP et n'a aucun effet positif sur l'amélioration de la précision [1]. Par conséquent, en considérant les résultats rapportés dans le tableau IV. 3, une approche MLP avec une seule couche cachée ayant 15 neurones est choisie comme la meilleure structure pour l'estimation du rapport de conductivité thermique du nanofluide Alumine/Eau.

Pour simuler le comportement d'un système donné par le réseau de neurones MLP, une quantité relativement étendue de données expérimentales est nécessaire. La figure IV. 6 représente la variation de Somme de l'erreur quadratique observée (L'erreur entre les prédictions MLP et les données réelles du TCR des nanofluides d'Alumine/Eau) en fonction du nombre d'époque.

Selon le processus d'optimisation, la meilleure architecture trouvée pour le taux de conductivité thermique est de **15** neurones dans la couche cachée.

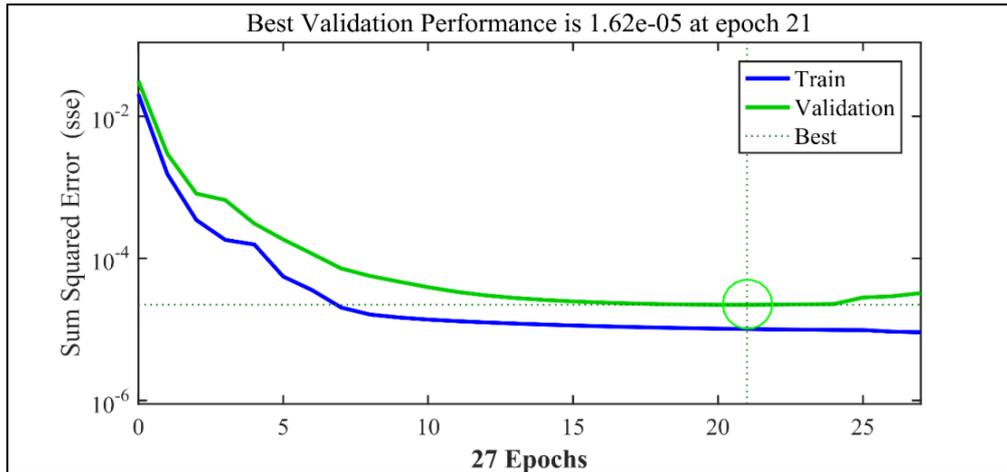


Figure IV.6: Apprentissage de RNA utilisant 15 neurones dans une couche cachée.

Comme mentionné précédemment, la procédure d'ajustement des poids et biais du modèle MLP est effectuée par une technique d'optimisation à savoir un algorithme d'apprentissage. Il est évident que la technique d'optimisation tente de minimiser la MSE observée ainsi que la SSE par une procédure d'itération. Dans la figure IV. 6, le terme d'époque (*Epoch*) montre le nombre d'interactions que l'algorithme d'apprentissage a essayé d'ajuster avec le paramètre MLP ; en utilisant la procédure donnée de la section IV.2.2.

On peut voir sur la figure IV. 6, qu'en augmentant le nombre d'itérations (c'est-à-dire l'époque), les poids et biais du modèle MLP convergent vers leur valeurs optimisées, et par conséquent, la SSE observée diminue continuellement. La meilleure performance de validation est de $1,62 \times 10^{-5}$ et ceci après 21 époques.

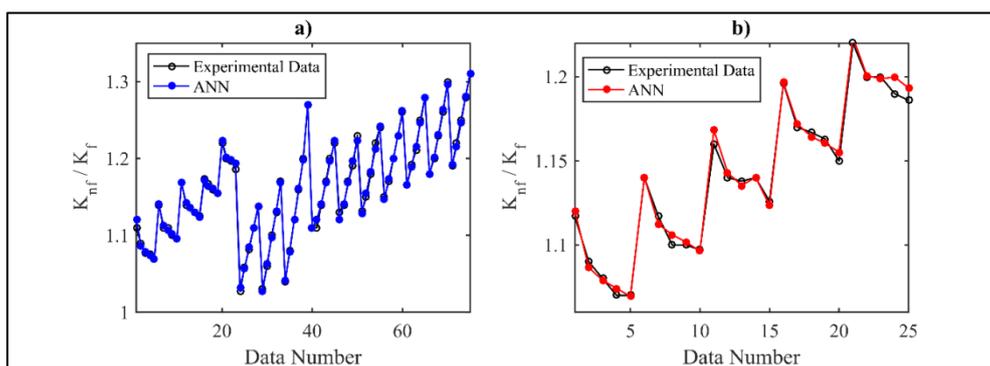


Figure IV. 7: Valeurs estimées du taux d'amélioration de conductivité thermique
 a) Données d'apprentissage, b) Données de validation.

La Figure IV.7 montre le contraste entre les valeurs déterminées expérimentalement et les valeurs prédites par RNA (*ANN*) pour l'apprentissage et la validation. On peut voir que la différence entre les valeurs déterminées expérimentalement et les valeurs prédites par RNA est assez petite, et le modèle est capable de prédire les valeurs de TCR des données invisibles, c'est-à-dire des données

de test avec une bonne précision. Il montre également que le modèle s'est bien adapté aux données et qu'il n'y a pas de surajustement dans le modèle malgré le nombre élevé d'itérations.

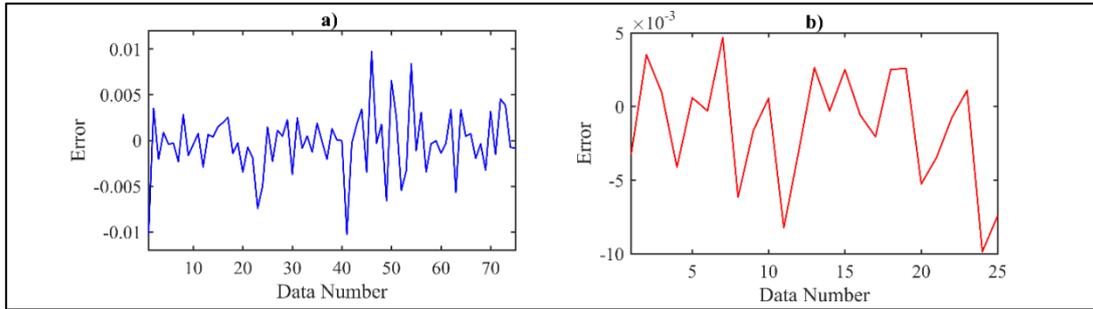


Figure IV. 8: Erreurs de RNA pour TCR

a) données d'apprentissage, b) données de validation.

La figure IV. 8 présente les erreurs du modèle MLP ($y_{exp} - y_{préd}$) pour la conductivité thermique de nanofluide (Al₂O₃/H₂O) en fonction du nombre des données expérimentales pour l'apprentissage et la validation. On observe que l'erreur maximale pour les données d'apprentissage est de 0.9% et celle pour tester les données est de 0.5%. On remarque aussi que les l'erreur pour les données d'apprentissage diminuent avec l'augmentation du nombre des données expérimentales.

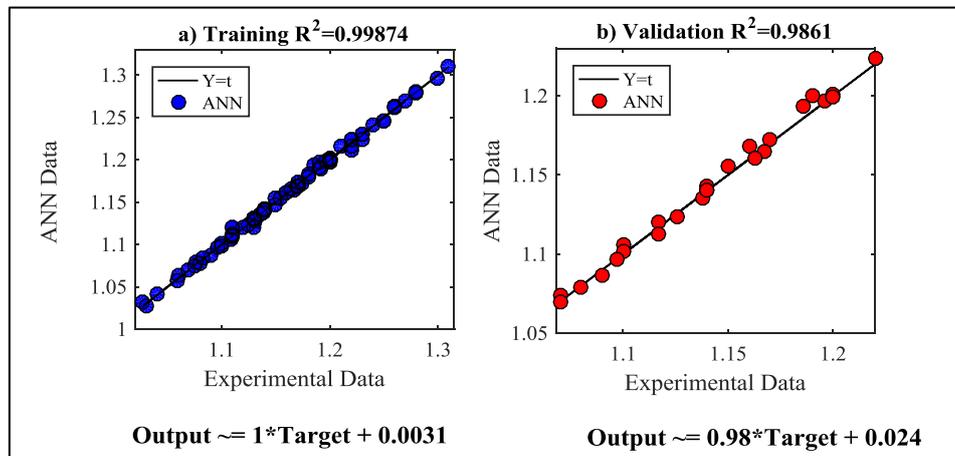


Figure IV.9: Graphe des données expérimentales du TCR en fonction des valeurs prédites par le meilleur modèle MLP. a) données d'apprentissage, b) données de validation

La figure IV. 9 montre la comparaison des résultats expérimentaux pour la conductivité thermique de nanofluide (Al₂O₃/H₂O) avec les résultats prédits obtenus en utilisant le modèle MLP optimal. Les résultats de l'apprentissage et de la validation sont ainsi présentés. La valeur R² de 0,99874 dans le processus d'apprentissage montre un coefficient de corrélation élevé. Aussi, comme on peut l'observer sur la figure IV.9.a, tous les points de données sont alignés le long de la ligne diagonale du graphique, qui montre un modèle de prédiction de haute performance.

La Figure IV.9.b exhibe la valeur R² de l'ensemble de données de validation qui est égale à 0,9861 confirmant autant une précision et une prédiction élevée.

Cela signifie qu'il existe un excellent accord entre les prédictions du modèle MLP et les données expérimentales réelles.

Tableau IV.4: Comparaisons de la précision prédictive de différentes corrélations intelligentes et empiriques de TCR expérimental mesuré par Chandrasekar et al. [41]

(Avec T = 35,5 °C et dp = 36 nm).

Fraction volumique d'Al ₂ O ₃	L'approche intelligente considérée et les corrélations empiriques							TCR Actuel [41]
	Chon et al. [42]	Murshed et al. [43]	Mintsa et al. [44]	Yu and Choi [45]	Xie et al. [46]	Nan et al. [47]	Modèle MLP	
0,01	1,0331	1,0818	1,0175	1,0341	1,0343	1,0292	1.037	1,032
0,02	1,0545	1,1646	1,0351	1,0672	1,0673	1,0584	1.077	1,074
0,03	1,076	1,2523	1,0516	1,1023	1,1025	1,0896	1.0963	1,096
AARD%	0,587	3,406	1,524	0,388	0,386	0,635	0.0019	—

Le tableau IV. 4 présente les résultats de l'estimation des données expérimentales TCR rapportées par Chandrasekar et al. [41] en utilisant notre modèle intelligent ainsi que diverses corrélations empiriques [42–47]. On peut clairement voir que notre modèle MLP proposé prédit les données expérimentales avec le plus petit écart à savoir (AARD = 0.0019 %). Les corrélations proposées par Yu et Choi [45] et Xie et al. [46] qui fournissent relativement de bons résultats avec (AARD = 0,39%) et sont ainsi parmi les meilleures corrélations empiriques.

La figure IV. 10 illustre la comparaison des données expérimentales de Chandrasekar et al. et du TCR prédit par notre modèle du nanofluide Al₂O₃/Eau en fonction de la fraction volumique pour un diamètre de particule de 36 nm et une température de 35,5 ° C [41].

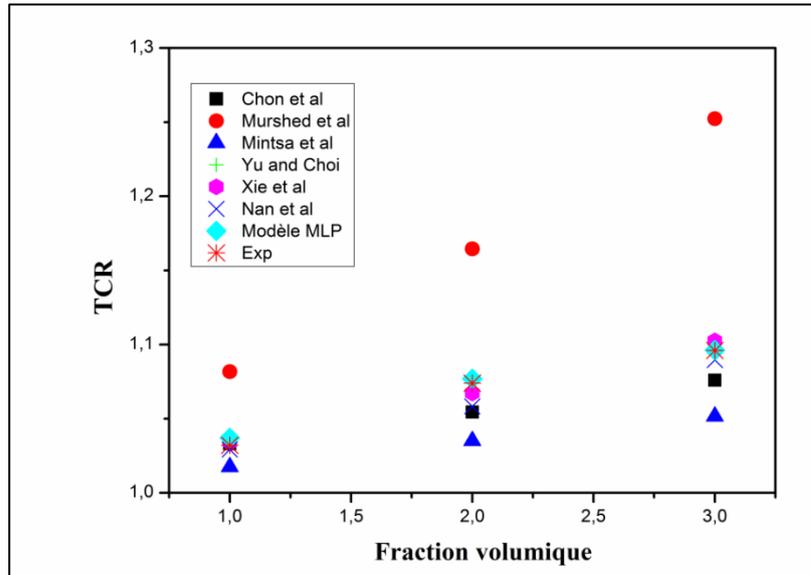


Figure IV.10: Évaluation comparative pour la prédiction de la TCR du nanofluide du modèle MLP développé avec des modèles classiques et expérimental mesuré par Chandrasekar et *al.* [41].

Les résultats indiquent que l'augmentation de la fraction volumique opérationnelle de 1 à 3% augmente la conductivité relative des nanofluides, les réseaux de neurones MLP sont en parfait accord avec les données expérimentales par rapport aux autres modèles.

IV.4.2 Estimation de la viscosité dynamique basée sur RNA

Similairement à la modélisation précédente de TCR, la meilleure structure du modèle MLP est sélectionnée par des analyses d'essais et d'erreurs. L'évaluation des modèles a été réalisée en utilisant à la fois les illustrations statistiques et graphiques. Les résultats de cette procédure ont été rapportés dans le tableau IV. 5 et la figure IV. 11. Différents modèles MLP ayant 1 à 25 neurones cachés ont été développés, entraînés, testés et leurs performances ont été évaluées.

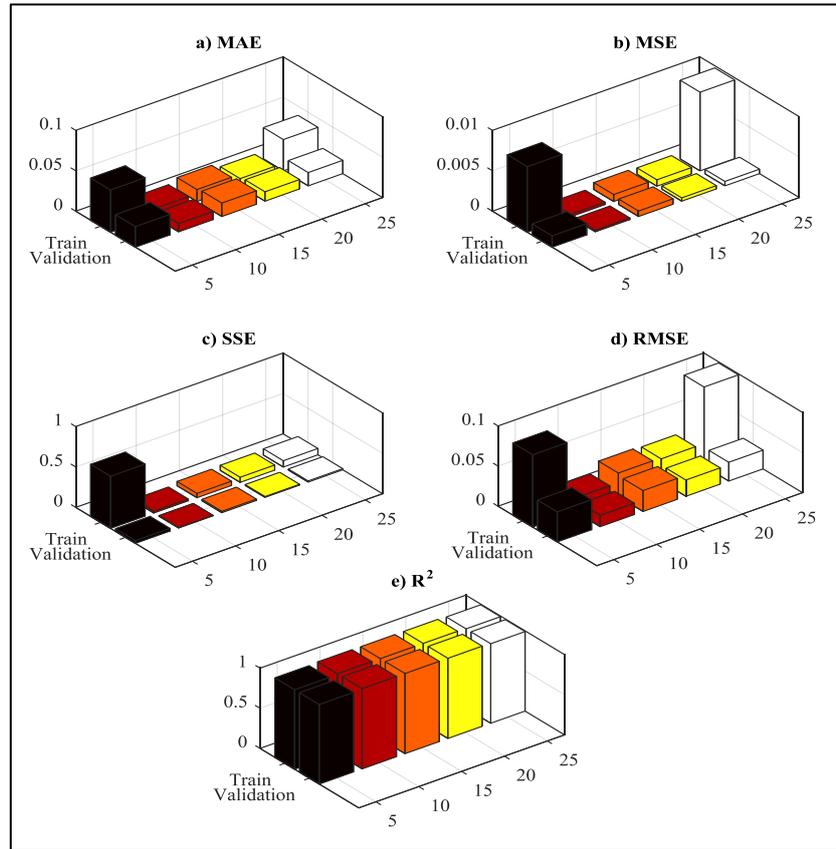


Figure IV.11: Comparaison statistique

La figure IV. 11 montre la variation de MSE, MAE, SSE, RMSE et R² des données d'apprentissage et de validation avec le nombre de neurones dans la couche cachée. Les résultats montrent que les valeurs MSE, MAE, SSE et RMSE sont les plus faibles lorsqu'il y a 20 neurones à la fois en apprentissage et en validation, Contrairement au R², qui prend dans tous les cas une valeur élevée, signifiant que le nombre optimal de neurones dans les couches cachées est de 20.

Tableau IV.5: Évaluation des performances du réseau de neurones MLP pour les échantillons d'entraînement et de test pour DVR.

Indicateur	Nombre de Neurones									
	Apprentissage					Test				
	5	10	15	20	25	5	10	15	20	25
MAE	5,22E-02	9,80E-03	1,48E-02	9,38E-03	3,87E-02	2,54E-02	1,01E-02	1,66E-02	1,16E-02	1,64E-02
MSE	8,10E-03	3,00E-04	8,63E-04	7,88E-04	9,73E-03	1,40E-03	2,00E-04	6,78E-04	4,09E-04	5,47E-04
SSE	6,44E-01	2,23E-02	5,31E-02	6,31E-02	7,79E-02	3,40E-02	4,50E-03	1,70E-02	1,02E-02	1,37E-02
RMSE	9,00E-02	1,73E-02	2,94E-02	2,81E-02	9,86E-02	3,74E-02	1,41E-02	2,60E-02	2,02E-02	2,34E-02
R ²	9,91E-01	1,00E+00	9,99E-01	9,99E-01	9,91E-01	9,91E-01	1,00E+00	9,99E-01	9,99E-01	9,91E-01

Les performances du modèle RNA pendant le processus d'apprentissage pour le taux de viscosité peuvent être discernées dans la figure IV. 12. Selon le processus d'optimisation, la

meilleure architecture trouvée pour le taux de viscosité est de 20 neurones dans la couche cachée. Il a été observé aussi que la meilleure performance de taux de viscosité est pour des valeurs de MSE égale à 0,0004089 observée à 12 époques.

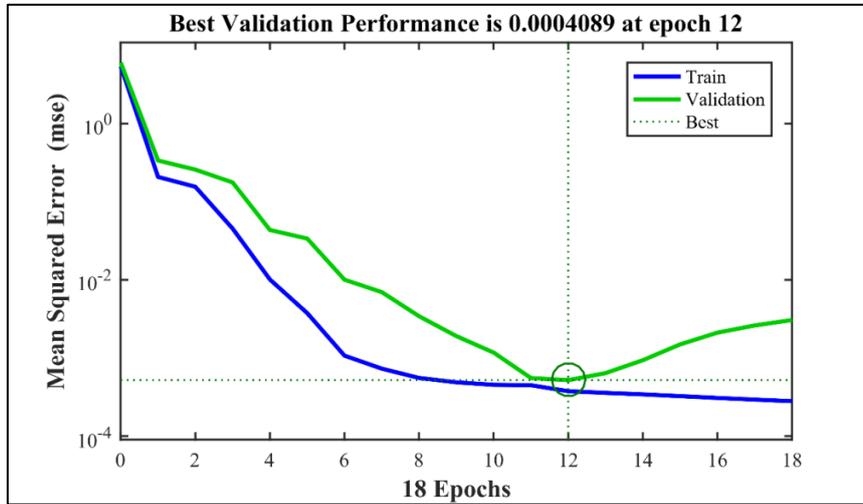


Figure IV.12: Apprentissage de RNA utilisant 20 neurones dans une couche cachée.

Une comparaison de la prédiction du réseau neuronal pour le taux de viscosité avec les données expérimentales correspondantes de l'ensemble de données d'apprentissage et de validation, est représentée sur la figure IV. 13. Dans la majorité des cas, le taux de viscosité prédit est très proche de la valeur observée expérimentalement. La manière dont la précision de la prédiction varie en fonction du nombre de points de données expérimentales dans l'ensemble de données d'apprentissage est particulièrement intéressante pour ce travail.

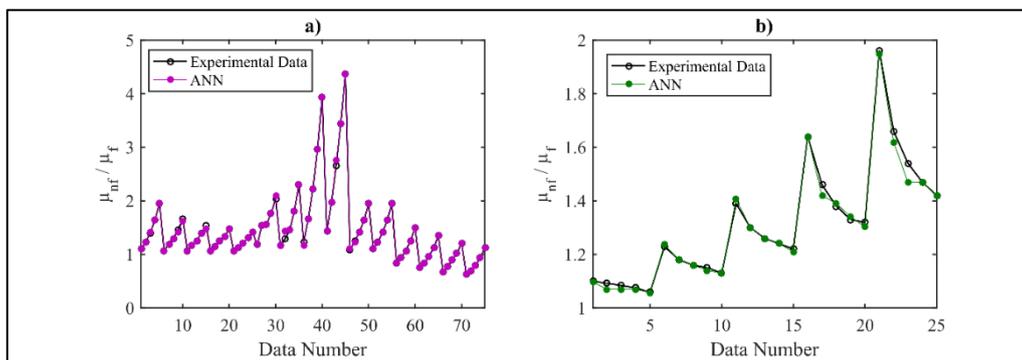


Figure IV.13: Valeurs estimées du rapport de viscosité
a) données d'apprentissage, b) données de validation

La figure IV. 14 expose les erreurs de modèle MLP ($y_{exp} - y_{préd}$) pour la viscosité dynamique relative (DVR) de nanofluide (Al₂O₃/H₂O) en fonction de nombre des données expérimentales pour l'apprentissage et la validation. On observe que l'erreur maximale pour les données d'apprentissage

est de 6,5% et l'erreur maximale pour tester les données est de 7%. On remarque aussi que les erreurs pour les données d'apprentissage diminuent avec l'augmentation du nombre des données expérimentales.

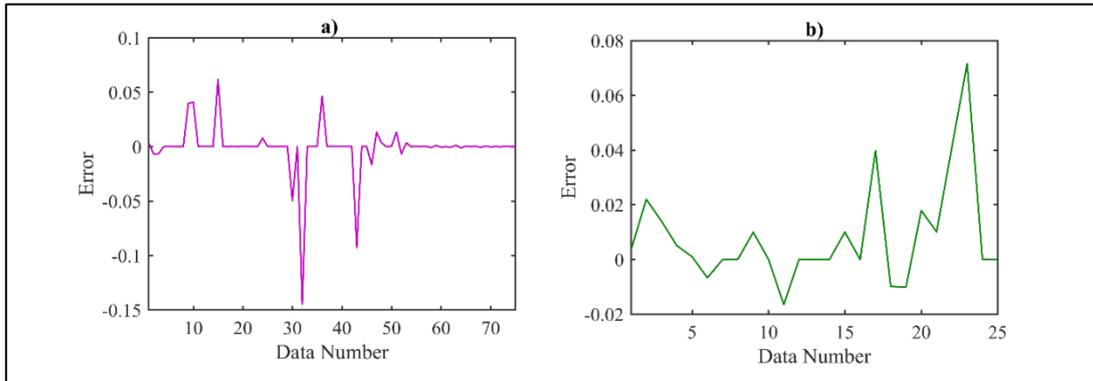


Figure IV.14: Erreurs de RNA pour DVR

a) données d'apprentissage, b) données de validation

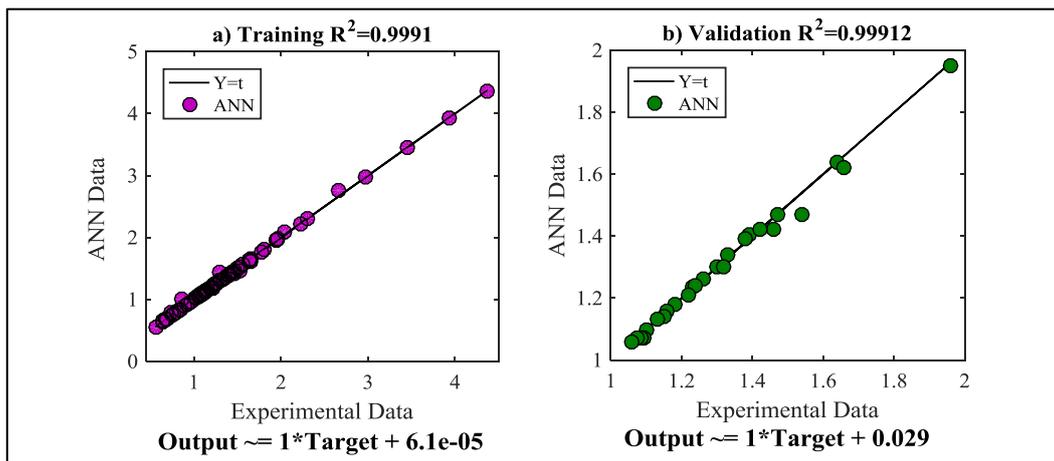


Figure IV. 15: Graphe des données expérimentales du DVR en fonction des valeurs prédites par le meilleur modèle MLP.

a) données d'apprentissage, b) données de validation.

La figure IV. 15 évoque la comparaison des résultats expérimentaux pour la viscosité dynamique relative (DVR) du nanofluide (Al₂O₃/H₂O) avec les résultats prédits en utilisant le modèle MLP optimal. Les résultats de l'apprentissage et de la validation sont ainsi présentés.

La figure IV. 15 montre d'excellents ajustements le long de la ligne d'égalité pour les sous-ensembles d'apprentissage et de validation. Les coefficients de régression R^2 sont également présentés avec chaque ensemble de données. La valeur des coefficients de régression proche de 1 indique une relation étroite entre les données expérimentales et les données estimées par RNA. On

peut voir aussi que la valeur des coefficients de régression est supérieure à 0,99 pour tous les jeux de données utilisés dans le présent modèle, confirmant une précision de prédiction élevée.

Plusieurs modèles capables de prédire la viscosité des nanofluides ont été sélectionnés pour être comparés à nos résultats. La figure IV.16, compare les résultats de prédiction de la viscosité relative des nanofluides (uniquement pour les données de teste), du modèle (MLP) proposé par nos soins avec ceux existants.

Afin d'évaluer les performances de prédiction des réseaux de neurones MLP pour le nanofluide Al₂O₃/Eau avec un diamètre de 36 nm et une faible concentration volumique de nanoparticules, la figure IV.16 présente les valeurs des AARD de notre modèle MLP comparé à celles d'autres modèles.

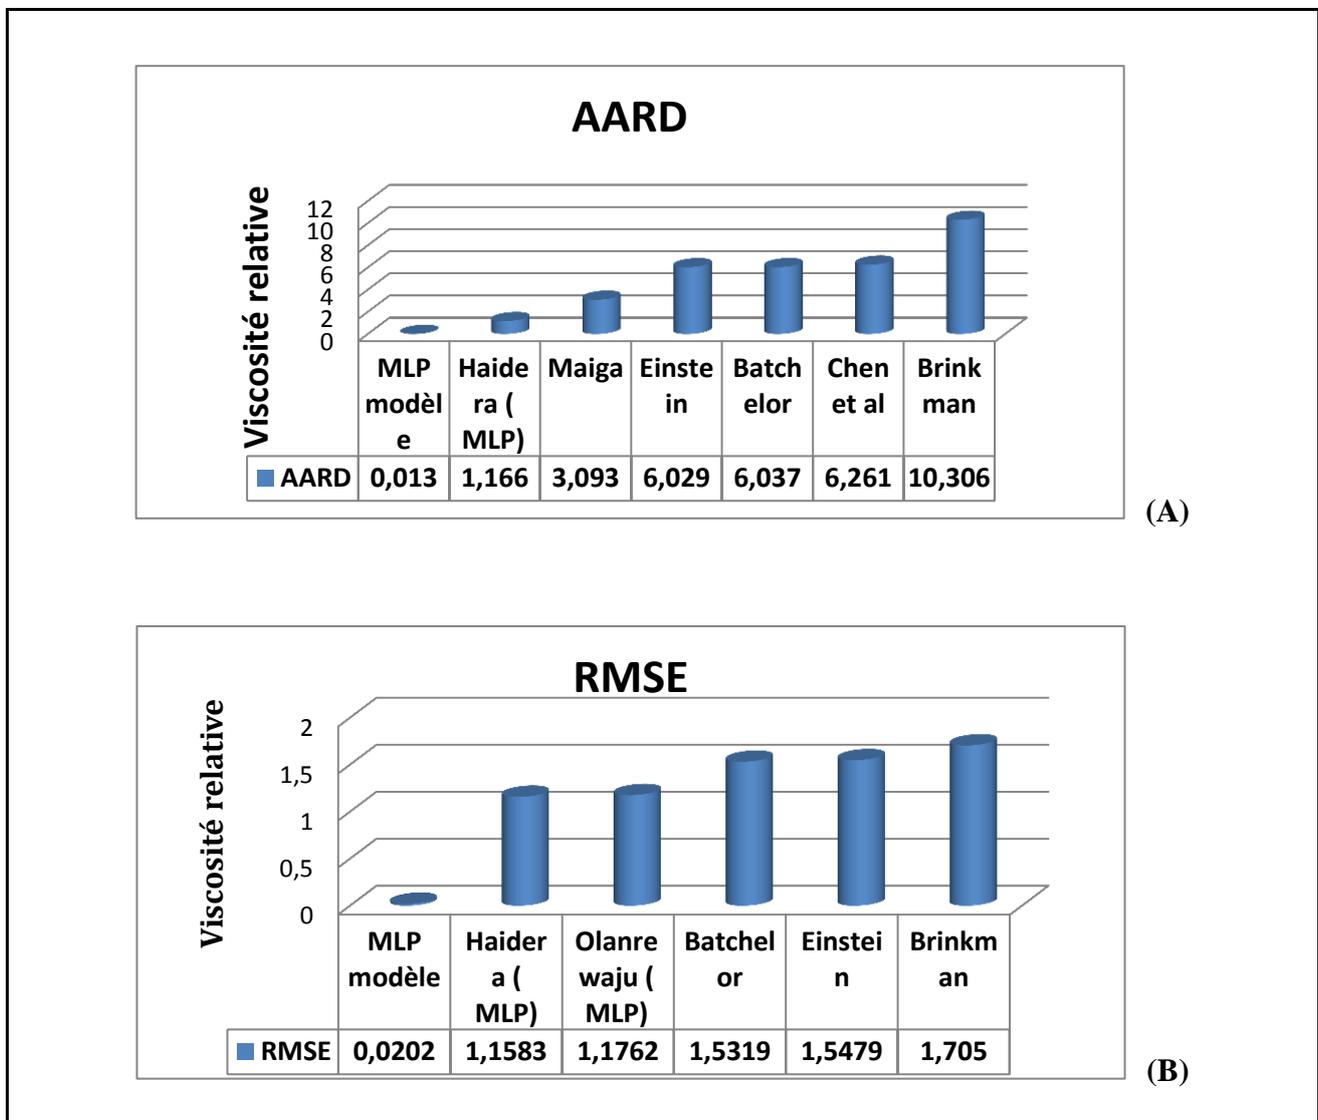


Figure IV. 16: Comparaison du modèle proposé (MLP) avec les modèles existants pour la prédiction de la viscosité relative des nanofluides.

En raison de la plus faible valeur de l'écart relatif absolu moyen (AARD = 0,013%) de notre réseau de neurones MLP par rapport aux autres modèles tels que Heidari et *al.* [48], Maiga et *al.* [49], Einstein [50], Batchelor [51], Chen et *al.* [52] et le modèle de Brinkman [53]. Nous démontrons ainsi que les réseaux de neurones MLP peuvent être utilisés avec une précision satisfaisante pour la prédiction de la viscosité des nanofluides Al₂O₃ / Eau.

Les valeurs de RMSE de notre model ainsi que des autres modèles sont également comparés dans la figure IV.16.B.

Le modèle MLP proposé par nos soins, montre une amélioration plus claire avec (RMSE = 0,0202) par rapport aux modèles RNA [31, 48], ainsi que par rapport à d'autres modèles de prédiction de viscosité [49, 51, 53]. Par exemple, le présent modèle a réduit l'erreur de prédiction (RMSE) de 1,705 à environ 0,0202 par rapport à Brinkman, indiquant une amélioration de 84-fois dans la prédiction de la viscosité.

IV.5 Conclusion

Dans la présente partie du travail, une procédure systématique basée sur le Réseau Neuronal Artificiel RNA est développée pour prédire la conductivité thermique et la viscosité de nanofluides (Al₂O₃/ Eau). La fraction volumique, la température, le diamètre et la forme des nanoparticules sont saisis en tant que paramètres indépendants (Entrées), le taux de conductivité thermique (k_{nf}/k_f) et le taux de viscosité (μ_{nf}/μ_f) sont considérés comme des paramètres dépendants.

Une approche MLP avec une seule couche cachée est choisie comme la meilleure structure pour l'estimation du rapport de conductivité thermique et de viscosité dynamique du nanofluide Alumine/Eau. Le nombre optimal de neurones dans les couches cachées sont 15 et 20 neurones pour le taux de conductivité thermique et de viscosité dynamique du nanofluide considéré respectivement.

Il ressort clairement de ces résultats que toutes les valeurs de (k_{nf}/k_f) se trouvent dans la ligne centrale, avec des valeurs de l'erreur quadratique moyenne (MSE) de 0,000018 pour l'apprentissage et de 0,0000162 pour la validation. De plus, le modèle (k_{nf}/k_f) fournit une bonne corrélation entre les valeurs prédites et expérimentales avec des valeurs de R² égales à 0,998 et 0,998 pour l'apprentissage et la validation. De même, une excellente corrélation est observée entre la réponse prédite et observée pour (μ_{nf}/μ_f). Ainsi, des valeurs plus élevées de R² = 0,999 et de faible valeurs de MSE = 0,000788 pour l'apprentissage ; et R² = 0,99 et MSE = 0,000678 pour la validation, donnant ainsi un bon accord entre les valeurs du modèle et les données expérimentales.

De plus, l'approche RNA sélectionnée prévoit un apprentissage avec un AARD de 0.013 % pour (μ_{nf}/μ_f) et de 0.0019 % pour (k_{nf}/k_f) .

Ces résultats montrent une excellente corrélation entre les réponses prédites et observées de (k_{nf}/k_f) et de (μ_{nf}/μ_f) , prouvant ainsi une bonne concordance entre les valeurs du modèle proposé et les valeurs des données expérimentales confirmant ainsi la validité et la faisabilité de la méthode adoptée.

La comparaison avec les diverses corrélations empiriques confirme que le modèle proposé à des performances supérieures dans la prédiction du TCR et du DVR des nanofluides Alumine/Eau et peut être considéré comme un outil pratique pour la tâche considérée.

IV.6 Références

- [1] Vaferi, B. (2020). Application of Artificial Neural Networks for Accurate Prediction of Thermal and Rheological Properties of Nanofluids. *Deterministic Artificial Intelligence*, 69.
- [2] Al Muallim, B., Wahid, M. A., Mohammed, H. A., Mohammed, M. K., Habibi, D. (2020). Thermal–Hydraulic Performance in a Microchannel Heat Sink Equipped with Longitudinal Vortex Generators (LVGs) and Nanofluid. *Processes*, 8(2), 231.
- [3] Kimpton, H., Cristaldi, D. A., Stulz, E., Zhang, X. (2020). Thermal performance and physicochemical stability of silver nanoprism-based nanofluids for direct solar absorption. *Solar Energy*, 199, 366-376.
- [4] Soylu, S. K., Atmaca, İ., Asiltürk, M., Doğan, A. (2019). Improving heat transfer performance of an automobile radiator using Cu and Ag doped TiO₂ based nanofluids. *Applied Thermal Engineering*, 157, 113743.
- [5] Li, X., Zeng, G., Lei, X. (2020). The stability, optical properties and solar-thermal conversion performance of SiC-MWCNTs hybrid nanofluids for the direct absorption solar collector (DASC) application. *Solar Energy Materials and Solar Cells*, 206, 110323.
- [6] Selvaraj, V., Krishnan, H. (2020). Synthesis of graphene encased alumina and its application as nanofluid for cooling of heat-generating electronic devices. *Powder Technology*, 363, 665-675.
- [7] Sint, N. K. C., Choudhury, I. A., Masjuki, H. H., Aoyama, H. (2017). Theoretical analysis to determine the efficiency of a CuO-water nanofluid based-flat plate solar collector for domestic solar water heating system in Myanmar. *Solar Energy*, 155, 608-619.
- [8] Ham, J., Kim, J., Cho, H. (2016). Theoretical analysis of thermal performance in a plate type liquid heat exchanger using various nanofluids based on LiBr solution. *Applied thermal*

engineering, 108, 1020-1032.

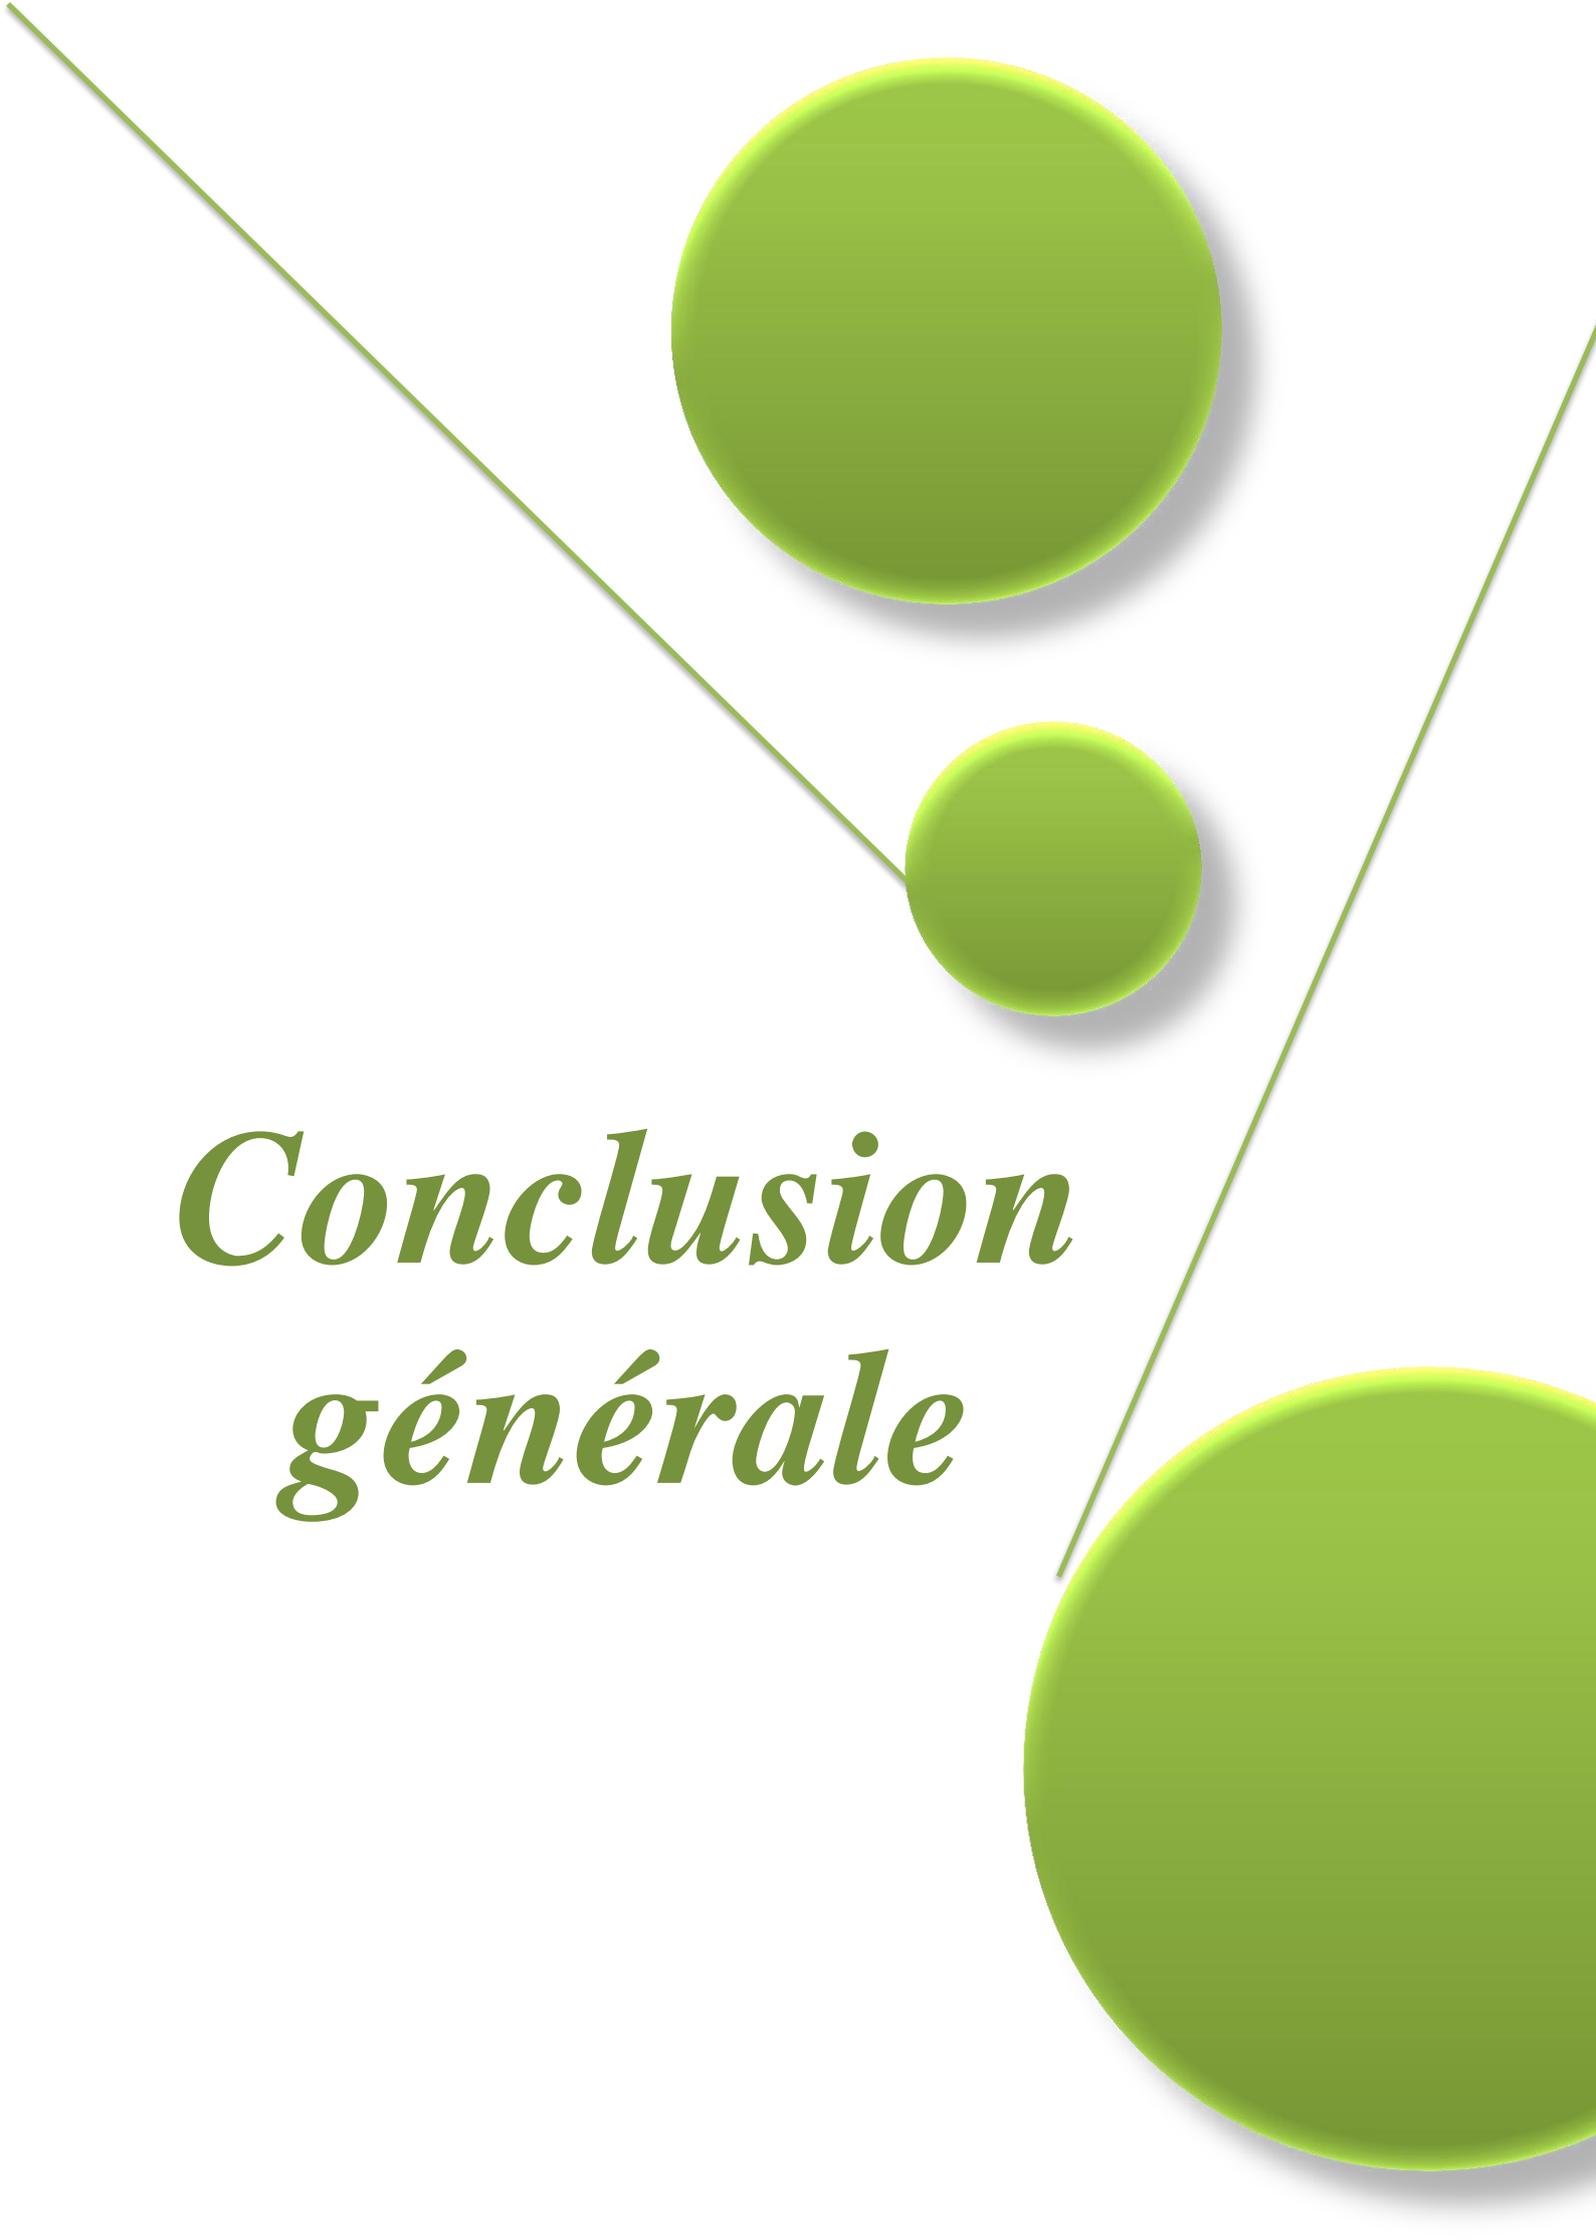
- [9] Jia, Y., Ran, F., Zhu, C., Fang, G. (2020). Numerical analysis of photovoltaic-thermal collector using nanofluid as a coolant. *Solar Energy*, 196, 625-636.
- [10] Saba, F., Noor, S., Ahmed, N., Khan, U., Mohyud-Din, S. T., Bano, Z., ... Khan, I. (2019). Heat transfer enhancement by coupling of carbon nanotubes and SiO₂ nanofluids: a numerical approach. *Processes*, 7(12), 937.
- [11] Ahmed, Z., Al-Qahtani, A., Nadeem, S., Saleem, S. (2019). Computational study of MHD nanofluid flow possessing micro-rotational inertia over a curved surface with variable thermophysical properties. *Processes*, 7(6), 387.
- [12] Li, M. J., Li, M. J., He, Y. L., Tao, W. Q. (2019). A novel semi-empirical model on predicting the thermal conductivity of diathermic oil-based nanofluid for solar thermal application. *International Journal of Heat and Mass Transfer*, 138, 1002-1013.
- [13] Sedaghat, F., Yousefi, F. (2019). Synthesizes, characterization, measurements and modeling thermal conductivity and viscosity of graphene quantum dots nanofluids. *Journal of Molecular Liquids*, 278, 299-308.
- [14] Charab, A. A., Movahedirad, S., Norouzbeigi, R. (2017). Thermal conductivity of Al₂O₃+TiO₂/water nanofluid: Model development and experimental validation. *Applied Thermal Engineering*, 119, 42-51.
- [15] Bardool, R., Bakhtyari, A., Esmailzadeh, F., Wang, X. (2019). Nanofluid viscosity modeling based on the friction theory. *Journal of Molecular Liquids*, 286, 110923.
- [16] Bakthavatchalam, B., Shaik, N. B., Hussain, P. B. (2020). An Artificial Intelligence Approach to Predict the Thermophysical Properties of MWCNT Nanofluids. *Processes*, 8(6), 693.
- [17] Mahian, O., Kolsi, L., Amani, M., Estellé, P., Ahmadi, G., Kleinstreuer, C., ... Pop, I. (2019). Recent advances in modeling and simulation of nanofluid flows-Part I: Fundamentals and theory. *Physics reports*, 790, 1-48.
- [18] Alrashed, A. A., Gharibdousti, M. S., Goodarzi, M., de Oliveira, L. R., Safaei, M. R., Bandarra Filho, E. P. (2018). Effects on thermophysical properties of carbon based nanofluids: experimental data, modelling using regression, ANFIS and ANN. *International Journal of Heat and Mass Transfer*, 125, 920-932.
- [19] Alrashed, A. A., Karimipour, A., Bagherzadeh, S. A., Safaei, M. R., Afrand, M. (2018). Electro-and thermophysical properties of water-based nanofluids containing copper ferrite nanoparticles coated with silica: experimental data, modeling through enhanced ANN and curve fitting. *International Journal of Heat and Mass Transfer*, 127, 925-935.
- [20] Hosseini, S. M., Safaei, M. R., Goodarzi, M., Alrashed, A. A., Nguyen, T. K. (2017). New

- temperature, interfacial shell dependent dimensionless model for thermal conductivity of nanofluids. *International Journal of Heat and Mass Transfer*, 114, 207-210.
- [21] Shahsavari, A., Khanmohammadi, S., Karimipour, A., Goodarzi, M. (2019). A novel comprehensive experimental study concerned synthesizes and prepare liquid paraffin-Fe₃O₄ mixture to develop models for both thermal conductivity & viscosity: a new approach of GMDH type of neural network. *International Journal of Heat and Mass Transfer*, 131, 432-441.
- [22] Bagherzadeh, S. A., D’Orazio, A., Karimipour, A., Goodarzi, M., Bach, Q. V. (2019). A novel sensitivity analysis model of EANN for F-MWCNTs–Fe₃O₄/EG nanofluid thermal conductivity: Outputs predicted analytically instead of numerically to more accuracy and less costs. *Physica A: Statistical Mechanics and Its Applications*, 521, 406-415.
- [23] Sadeghi, G., Nazari, S., Ameri, M., Shama, F. (2020). Energy and exergy evaluation of the evacuated tube solar collector using Cu₂O/water nanofluid utilizing ANN methods. *Sustainable Energy Technologies and Assessments*, 37, 100578.
- [24] Naphon, P., Wiriyasart, S., Arisariyawong, T., Nakharintr, L. (2019). ANN, numerical and experimental analysis on the jet impingement nanofluids flow and heat transfer characteristics in the micro-channel heat sink. *International Journal of Heat and Mass Transfer*, 131, 329-340.
- [25] Aminian, A. (2016). Predicting the effective thermal conductivity of nanofluids for intensification of heat transfer using artificial neural network. *Powder Technology*, 301, 288-309.
- [26] Hojjat, M., Etemad, S. G., Bagheri, R., Thibault, J. (2011). Thermal conductivity of non-Newtonian nanofluids: experimental data and modeling using neural network. *International journal of heat and mass transfer*, 54(5-6), 1017-1023.
- [27] Adun, H., Wole-Osho, I., Okonkwo, E. C., Bamisile, O., Dagbasi, M., Abbasoglu, S. (2020). A neural network-based predictive model for the thermal conductivity of hybrid nanofluids. *International Communications in Heat and Mass Transfer*, 119, 104930.
- [28] Zhao, N., Li, Z. (2017). Experiment and artificial neural network prediction of thermal conductivity and viscosity for alumina-water nanofluids. *Materials*, 10(5), 552.
- [29] Pare, A., Ghosh, S. K. (2021). A unique thermal conductivity model (ANN) for nanofluid based on experimental study. *Powder Technology*, 377, 429-438.
- [30] He, W., Ruhani, B., Toghraie, D., Izadpanahi, N., Esfahani, N. N., Karimipour, A., Afrand, M. (2020). Using of artificial neural networks (ANNs) to predict the thermal conductivity of zinc oxide–silver (50%–50%)/water hybrid Newtonian nanofluid. *International*

Communications in Heat and Mass Transfer, 116, 104645.

- [31] Alade, I. O., Rahman, M. A. A., Hassan, A., Saleh, T. A. (2020). Modeling the viscosity of nanofluids using artificial neural network and Bayesian support vector regression. *Journal of Applied Physics*, 128(8), 085306.
- [32] Parashar, N., Seraj, M., Yahya, S. M., Anas, M. (2020). Development of an artificial neural network for the prediction of relative viscosity of ethylene glycol based nanofluids. *SN Applied Sciences*, 2(9), 1-9.
- [33] TIGHILT, Y. (2011). Identification des antennes microrubans multicouches par la méthode spectrale et les réseaux de neurones. Doctoral dissertation, Ferhat Abbas –Setif. Algeria.
- [34] Chehaidia, S. E., Abderezzak, A., Kherfane, H., Boukhezzar, B., Cherif, H. (2020). An improved machine learning techniques fusion algorithm for controls advanced research turbine (cart) power coefficient estimation. *UPB Scientific Bulletin, Series C: Electrical Engineering and Computer Science*, 82,279-292.
- [35] Alawi, O. A., Sidik, N. A. C., Xian, H. W., Kean, T. H., Kazi, S. N. (2018). Thermal conductivity and viscosity models of metallic oxides nanofluids. *Int J Heat Mass Transfer*, 116, 1314-1325.
- [36] Dreyfus, G., Martinez, J. M., Samuelides, M., Gordon, M. B., Badran, F., Thiria, S. (2002). *Apprentissage statistique*. Groupe Eyrolles, 77. ISBN: 978-2-212-12229-9.
- [37] Kalogirou, S. A. (2001). Artificial neural networks in renewable energy systems applications: a review. *Renewable and sustainable energy reviews*, 5(4), 373-401.
- [38] Mellit, A., Kalogirou, S. A., Hontoria, L., Shaari, S. (2009). Artificial intelligence techniques for sizing photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*, 13(2), 406-419.
- [39] McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- [40] Kahaji, A., Alaoui, R., Farhat, S., Bouhouch, L. (2013). Modèle de prédiction des performances énergétiques des alimentations photovoltaïques par l'architecture MLP. *Revue Méditerranéenne des Télécommunications*, 3(1).
- [41] Chandrasekar, M., Suresh, S., Bose, A. C. (2010). Experimental investigations and theoretical determination of thermal conductivity and viscosity of Al_2O_3 /water nanofluid. *Experimental Thermal and Fluid Science*, 34(2), 210-216.
- [42] Chon, C. H., Kihm, K. D., Lee, S. P., Choi, S. U. (2005). Empirical correlation finding the role of temperature and particle size for nanofluid (Al_2O_3) thermal conductivity enhancement. *Applied Physics Letters*, 87(15), 153107.

- [43] Murshed, S. M. S., Leong, K. C., Yang, C. (2008). Investigations of thermal conductivity and viscosity of nanofluids. *International Journal of Thermal Sciences*, 47(5), 560-568.
- [44] Mintsu, H. A., Roy, G., Nguyen, C. T., Doucet, D. (2009). New temperature dependent thermal conductivity data for water-based nanofluids. *International journal of thermal sciences*, 48(2), 363-371.
- [45] Yu, W., Choi, S. U. S. (2003). The role of interfacial layers in the enhanced thermal conductivity of nanofluids: a renovated Maxwell model. *Journal of nanoparticle research*, 5(1), 167-171.
- [46] Xie, H., Fujii, M., Zhang, X. (2005). Effect of interfacial nanolayer on the effective thermal conductivity of nanoparticle-fluid mixture. *International Journal of Heat and Mass Transfer*, 48(14), 2926-2932.
- [47] Nan, C. W., Birringer, R., Clarke, D. R., Gleiter, H. (1997). Effective thermal conductivity of particulate composites with interfacial thermal resistance. *Journal of Applied Physics*, 81(10), 6692-6699.
- [48] Heidari, E., Sobati, M. A., Movahedirad, S. (2016). Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN). *Chemometrics and intelligent laboratory systems*, 155, 73-85.
- [49] Maïga, S. E. B., Nguyen, C. T., Galanis, N., Roy, G. (2004). Heat transfer behaviours of nanofluids in a uniformly heated tube. *Superlattices and Microstructures*, 35(3-6), 543-557.
- [50] Einstein, A. (1905). *Eine neue Bestimmung der Moleküldimensionen*. Doctoral dissertation, ETH Zurich.
- [51] Batchelor, G. K. (1977). The effect of Brownian motion on the bulk stress in a suspension of spherical particles. *Journal of fluid mechanics*, 83(1), 97-117.
- [52] Chen, H., Ding, Y., Tan, C. (2007). Rheological behaviour of nanofluids. *New journal of physics*, 9(10), 367.
- [53] Brinkman, H. C. (1952). The viscosity of concentrated suspensions and solutions. *The Journal of Chemical Physics*, 20(4), 571-571.

The background features a white surface with three large, vibrant green circles of varying sizes. Two thin, light green lines intersect to form a large 'V' shape. One line starts from the top left and ends near the center of the medium-sized circle. The other line starts from the top right and ends near the bottom right of the large circle. The text is centered in the lower-left quadrant of the page.

*Conclusion
générale*

Conclusion générale

En l'absence de l'outil expérimental, il devient impératif d'utiliser l'outil informatique pour palier à cette carence. Les plans factoriels complets et les réseaux de neurones artificiels ont pu remplacer le travail expérimental en simulant tous les phénomènes observés au laboratoire avec une erreur très faible.

Le travail entamé dans cette thèse se décline en deux parties distinctes :

La première partie est consacrée à l'étude de l'influence de quatre facteurs sur la conductivité thermique des nanofluides, Ces facteurs sont : la fraction volumique, la température, le diamètre et le type des nanoparticules. Un modèle mathématique est développé pour prédire la conductivité thermique des nanofluides d'Oxydes métalliques/Eau avec des nanoparticules d' Al_2O_3 , TiO_2 et CuO , en utilisant un plan d'expérience (Design of Experiments DOE), ensuite ce modèle est testé et analysé par la méthode ANOVA pour déterminer les effets des différents facteurs et leurs interactions. Une méthode factorielle complète à deux niveaux est considérée pour chaque facteur, puis les résultats sont analysés. Cette modélisation est basée sur des données expérimentales recueillies dans la littérature, et les résultats prédits ont été comparés à ceux d'autres modèles ainsi qu'aux résultats expérimentaux. Les résultats obtenus montrent que la fraction volumique des particules a l'effet le plus significatif sur l'amélioration de la conductivité thermique des nanofluides par rapport aux autres facteurs. Une augmentation de la fraction volumique et de la température des particules possède un effet favorable sur l'amélioration de la conductivité thermique des nanofluides, tandis qu'une taille de particule plus grande tend à la réduire. Ainsi, la concentration optimale de nanoparticules est essentielle à l'amélioration des performances des systèmes thermiques. Enfin, les résultats obtenus confirment la capacité du modèle proposé dans notre étude à prédire la conductivité thermique des nanofluides avec une grande précision.

La seconde partie est dédiée à la modélisation de la conductivité thermique et de la viscosité de nanofluide $\text{Al}_2\text{O}_3/\text{Eau}$ se basant sur la méthode de réseau neuronal artificiel. Prenant en compte la température, la fraction volumique, la taille et la forme de nanoparticules comme paramètres indépendants (en tant qu'entrées), le rapport de conductivité thermique (k_{nf}/k_f) et le rapport de viscosité (μ_{nf}/μ_f) sont considérés quant à eux comme des paramètres dépendants (en tant que sorties). Une approche MLP avec une

seule couche cachée est choisie comme la meilleure structure pour l'estimation du rapport de conductivité thermique et de viscosité dynamique du nanofluide Alumine-Eau, via de l'algorithme Levenberg–Marquardt (LM). Les nombre optimal de neurones dans les couches cachées sont 15 et 20 neurones pour le rapport de conductivité thermique et de viscosité dynamique du nanofluide considéré respectivement. La discussion des résultats obtenue, l'évaluation de la corrélation générée qui est effectuée par une comparaison avec d'autres corrélations appliquées au même régime, ainsi que la détermination des erreurs absolues et réelles, ont été représentés dans ce chapitre.

Les principaux résultats qu'on peut ressortir de cette thèse sont les suivants :

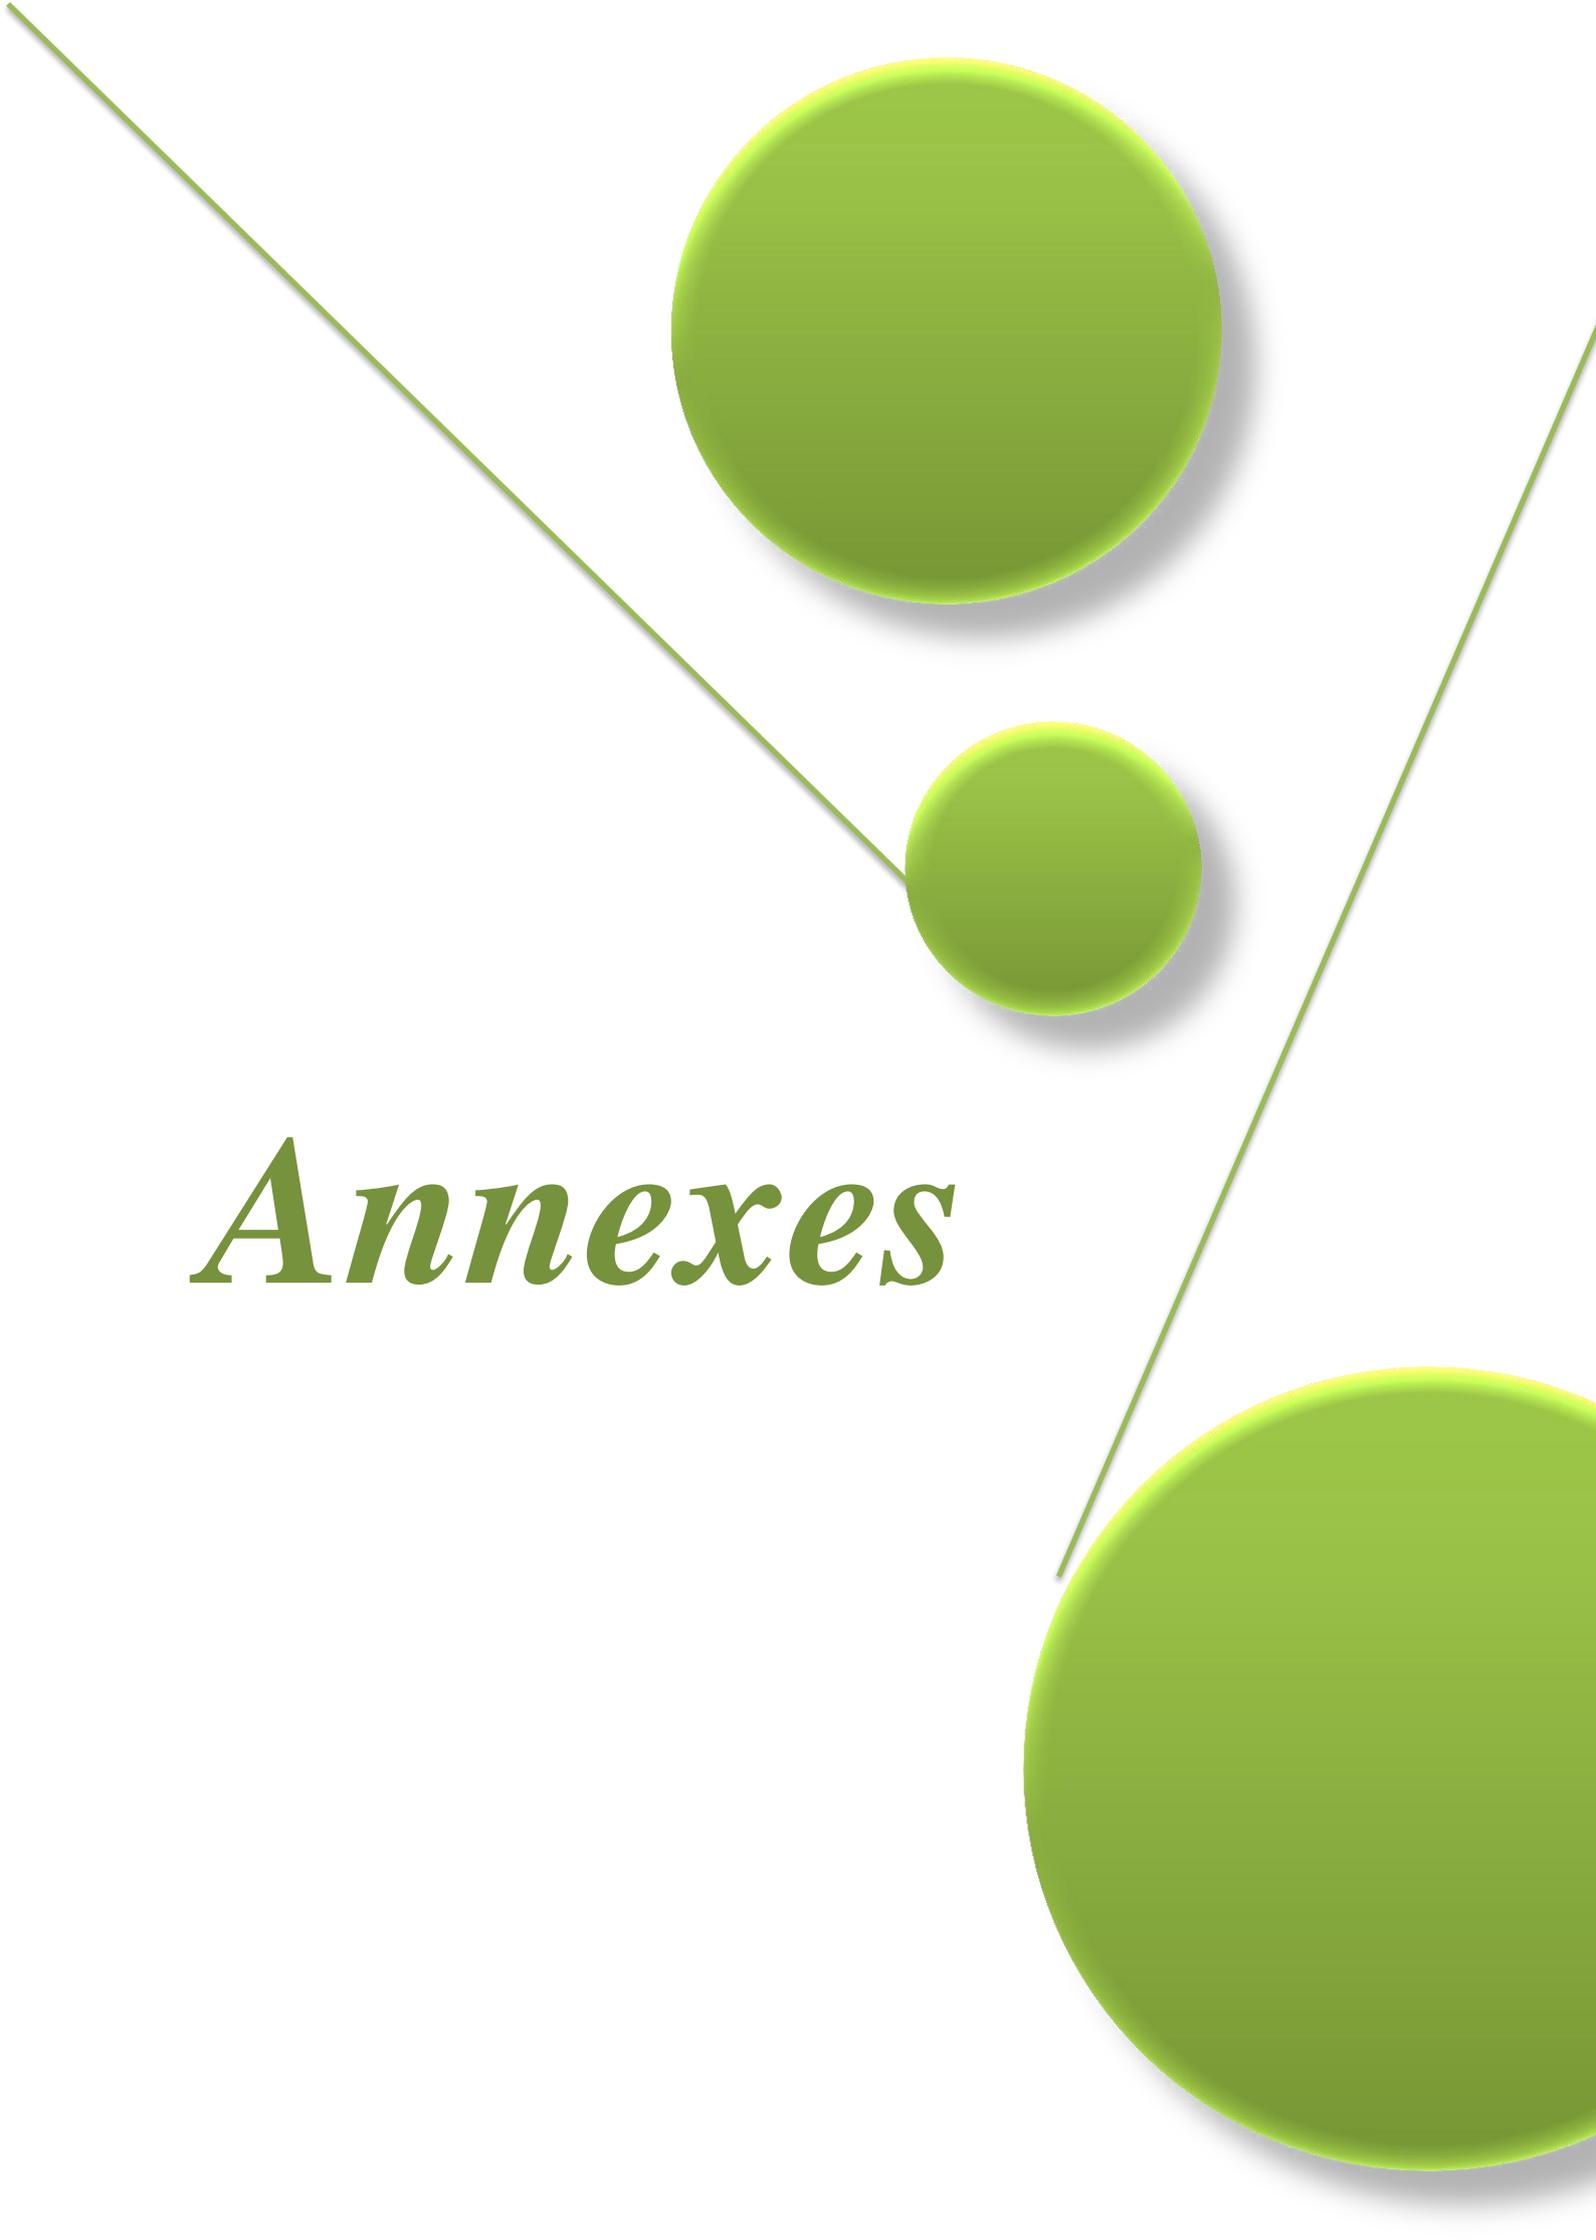
- Les valeurs R^2 et RMSE de 0,99 et 0,0074 respectivement, Ceci indique ainsi que le modèle de TCR fournit une bonne corrélation et que les valeurs prédites et expérimentales s'adaptent parfaitement.
- La fraction volumique des particules a l'effet le plus significatif sur l'amélioration de TCR par rapport aux autres facteurs.
- Une augmentation de la fraction volumique et de la température des particules possède un effet favorable sur l'amélioration de la conductivité thermique des nanofluides.
- Plus la taille des particules est grande, plus le TCR est bas.
- Une bonne concordance entre le modèle de TCR obtenu et les données expérimentales.
- La meilleure architecture trouvée pour le taux de TCR et DVR est de 15 et 20 neurones dans la couche cachée respectivement.
- Le modèle (k_{nf}/k_f) fournit une bonne corrélation entre les valeurs prédites et expérimentales avec des valeurs de R^2 égales à 0,998 et 0,998 pour l'apprentissage et la validation. De plus, les valeurs de MSE de 0,000018 pour l'apprentissage et de 0,0000162 pour la validation.
- Une excellente corrélation est observée entre la réponse prédite et observée pour (μ_{nf}/μ_f) . Ainsi, des valeurs plus élevées de $R^2 = 0,999$ et de faible MSE = 0,000788 pour l'apprentissage, $R^2 = 0,99$ et SME = 0,000678 pour la validation.
- Les valeurs AARD de 0.013 % pour (μ_{nf}/μ_f) et de 0.0019 % pour (k_{nf}/k_f) montrent une excellente corrélation entre les réponses prédites et observées de (k_{nf}/k_f) et de (μ_{nf}/μ_f) .

- La comparaison avec les diverses corrélations empiriques confirme que le modèle proposé a des performances supérieures dans la prédiction du TCR et du DVR des nanofluides Alumine-Eau et peut être considéré comme un outil pratique pour la tâche considérée.

Une première perspective pour des améliorations futures est de continuer l'analyse du transfert de chaleur en mettant en exergue des nouveaux modèles prédictifs de la conductivité thermique et de la viscosité qui tiennent en compte des effets du mouvement Brownien, de la couche inter-faciale entre nanoparticules et fluide de base ainsi que le phénomène d'agrégation qui pourraient être des mécanismes à l'origine de l'augmentation de conductivité thermique du nanofluide. Il sera intéressant d'étudier l'impact de ces modèles sur le transfert thermique, mais il faudra de comparaisons avec de données expérimentales pour trouver le meilleur.

Une autre voie est de simuler les nanofluides comme un fluide multi-composant. En d'autres mots, au lieu de considérer un seul milieu continu ayant de nouvelles propriétés et dans lesquels les particules sont dissoutes, on considère le fluide de base et les particules solides comme des éléments séparés.

Ainsi que, l'avantage de l'emploi des nanofluides en tant que fluides caloporteurs dépend fortement d'un compromis entre l'augmentation de la conductivité thermique et l'augmentation de la viscosité. Les futures recherches devront donc être dirigées vers la sélection de matériaux, de forme et de taille de nanoparticules qui augmenteraient la conductivité thermique du mélange avec une augmentation modérée de la viscosité. Par exemple, l'usage de particules non-sphériques conférant un caractère rhéofluidifiant au mélange est une voie à explorer. En outre, les futures recherches devront également prendre en compte l'encrassement éventuel des conduites par les nanofluides et d'en étudier les causes.

A decorative graphic featuring three green circles of varying sizes and two thin green lines. One line starts at the top left and ends at the center of the smallest circle. Another line starts at the top right and ends at the bottom right edge of the largest circle. The circles have a slight gradient and a soft shadow.

Annexes

I. Facteurs influençant les propriétés thermophysiques des nanofluides

Les paramètres principaux qui influent sur la conductivité thermique du nanofluide sont les suivants:

I.1 Effet de la concentration volumique de particules

L'effet de la concentration volumique des particules sur l'amélioration de la conductivité thermique du nanofluide est montré dans les figures I-1.a et I-1.b, (travaux de sept groupes de chercheurs pour les nanoparticules d' Al_2O_3 suspendus dans l'eau). La dimension de la particule et la température du nanofluide varient, cependant la tendance générale montre que la conductivité thermique augmente avec la fraction volumique des particules et que les concentrations de particules d'Oxyde métallique donne une amélioration allant jusqu'à 30% [1].

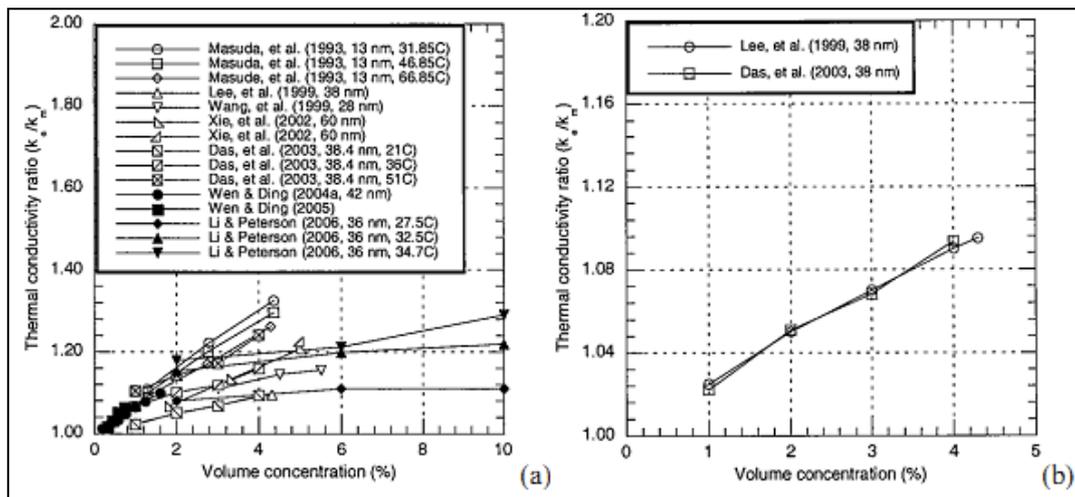


Figure I.1 : Effet de la concentration volumique sur la conductivité thermique du nanofluide (Al_2O_3 /Eau) pour différents chercheurs [1].

I.2 Effet du type de nanoparticules

Les figures I-2.a et I-2.b regroupent les résultats des études expérimentales de plusieurs chercheurs. Elles illustrent l'effet du type des nanoparticules sur la conductivité thermique pour deux types de nanofluides (un oxyde métallique et le second est un métal), tous deux sont dilués dans l'eau. Avec tous les paramètres (température et forme de la particule) sont supposés constants. Les résultats montrent que les particules métalliques produisent la même amélioration que les oxydes métalliques mais pour de faibles concentrations volumiques. On observe aussi que le rapport de la conductivité thermique du métal augmente plus rapidement que celui des oxydes métalliques [1].

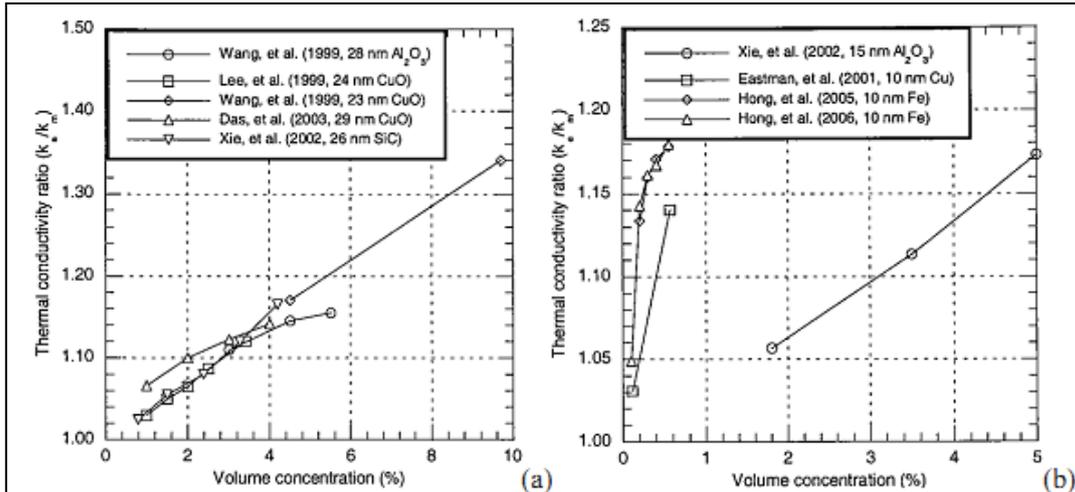


Figure I.2 : Effet des types de particules sur la conductivité thermique des nanofluides [1].

I.3 Effet de la température

En général, la conductivité thermique du nanofluide est sensible à la température par rapport au fluide de base. Par conséquent, l'amélioration de la conductivité thermique du nanofluide est également sensible à la température et augmente en fonction d'elle. Les résultats obtenus par Das et al. [2] pour des nanoparticules d'Al₂O₃/Eau et CuO/Eau avec un intervalle de température de 28°C à 51°C, indiquent clairement que la conductivité thermique augmente lorsque la température augmente. Mais elle est plus élevée pour l'oxyde de cuivre CuO par rapport à l'oxyde d'aluminium Al₂O₃. Où le taux de la conductivité thermique pour une concentration volumique $\phi=4\%$ et une température $T=51^\circ\text{C}$, atteint une valeur de 1,24 pour l'Al₂O₃ et 1,36 pour le CuO.

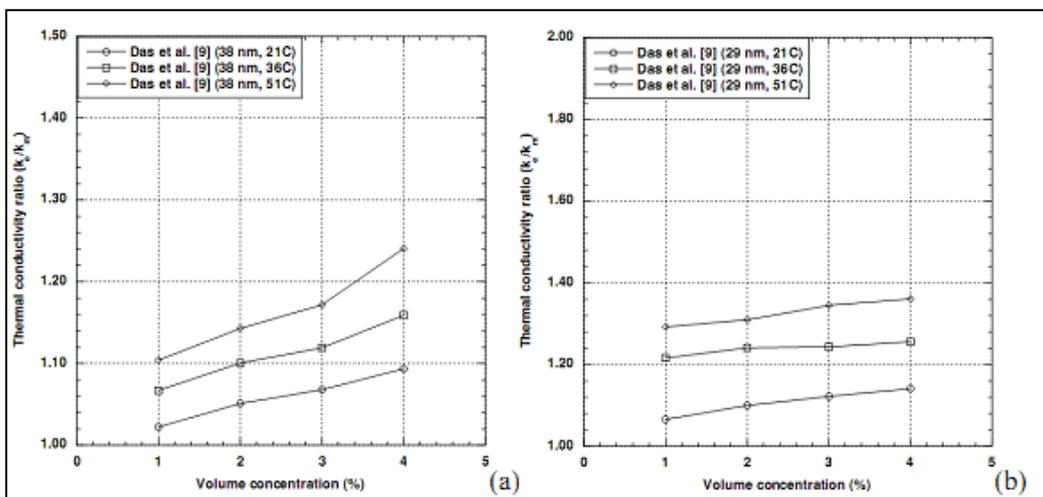


Figure I.3 : Effet de la température sur la conductivité thermique des nanofluides à base d'eau : (a) pour Al₂O₃, (b) pour CuO [1].

I.4 Effet de la taille des particules

La conductivité thermique d'un nanofluide augmente avec la diminution de la taille des particules. Ce phénomène est dû aux effets du mouvement Brownien des particules, Teng et *al.* [3] ; Le coefficient de diffusion Brownien augmente lorsqu'on réduit la taille des particules ; plus les particules sont petites plus la probabilité de collision entre elle augmente et meilleure est la conductivité thermique.

$$D_b = \frac{k_p T}{3\pi\mu d_p} 10^9 \quad (\text{A.1})$$

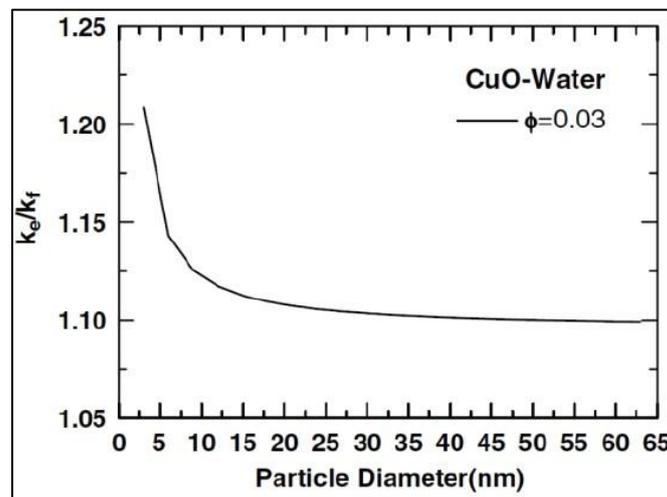


Figure I.4 : Influence du diamètre des particules sur la conductivité thermique.

Le mécanisme de la couche inter-faciale solide-liquide renforce la théorie stipulant que la diminution de la taille des particules augmente la conductivité thermique des nanofluides.

Yu et *al.* [1] prétendent le contraire ; plus les particules sont grandes plus la conductivité thermique augmente. Özerinç [4] ainsi que Bazan [5] ont également trouvé de grandes disparités concernant l'évolution de la conductivité en fonction de la taille des particules. Pour un nanofluide Al-Ethylène-Glycol, Xie et *al.* [6] ont révélé une augmentation de la conductivité pour des particules de grandes tailles (environ 60 nm) et une diminution pour les petites particules. Özerinç explique cela par l'effet du groupement (clustering) ; plus les particules sont petites plus cet effet est important.

I.5 Effet de la géométrie des particules

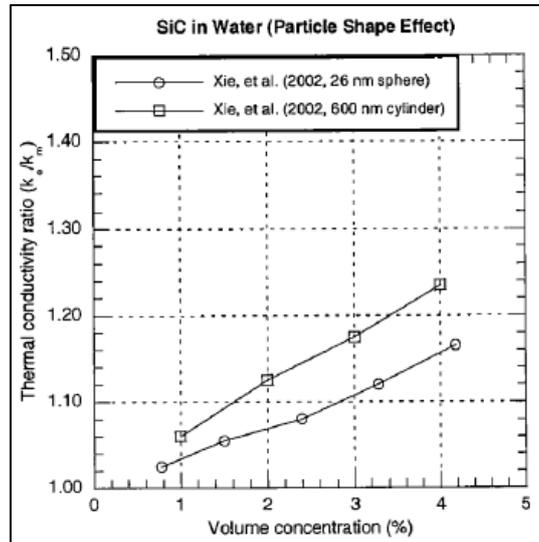


Figure I.5 : Influence de la géométrie des particules sur la conductivité thermique [1].

Aucune amélioration du transfert de chaleur n'est observée dans le cas de particules en forme de disque. Le graphique de la figure I.5 montre que des particules à géométrie cylindrique (longueur indiquée) donnent une meilleure conductivité que des particules sphériques. Timofeeva et *al.* [7] ont étudié l'influence de la géométrie des particules sur les propriétés physiques (conductivité, viscosité et pH du fluide). Les nanofluides les plus utilisés ont des particules sphériques car leur production est moins coûteuse que celle des particules cylindriques, par exemple.

I.6 Effet de pH du fluide

Les études sur l'influence de l'acidité du fluide porteur d'un nanofluide sur la conductivité thermique de ce dernier sont assez limitées. Özerinç, Yu et *al.* ainsi que Xie et *al.* [1, 4, 6] prétendent que la valeur du pH influence la conductivité thermique ; ils ont constaté un optimum pour un pH compris entre 2 et 3.

Timofeeva et *al.* [7] ont déterminé l'influence du pH sur la conductivité thermique d'un nanofluide à base de particules cylindriques associées à de l'éthylène glycol ou de l'eau et avec des pH de 2,54 ; 3,33 et 4,10. Ils ont constaté que le pH influence peu la conductivité thermique et que la viscosité des fluides augmente en diminuant le pH.

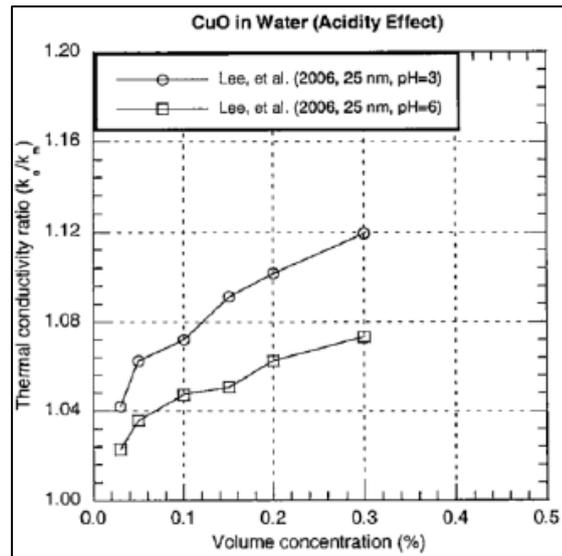


Figure I.6 : Influence du pH sur la conductivité thermique d'un nanofluide CuO/Eau (APS=60nm) [1].

II. Caractéristiques des nanofluides adoptées par différents chercheurs

Les tableaux suivants présentent un résumé des résultats obtenus par différents groupes de recherche de taux de la conductivité thermique pour différentes variables principales et ceci pour des oxydes métalliques, des métaux et carbone silicone.

a. Les oxydes métalliques

Tableau II.1 : Effet de la taille des particules sur la conductivité thermique [1].

Auteur (Année)	Nanofluide	Concentration	Taille	Amélioration
Lee et col (1999)	Al ₂ O ₃ / Eau	1,00-4.30	38.4	1.03-1.10
	CuO/ Eau	1.00-3.41	23.6	1.03-1.12
	Al ₂ O ₃ / EG	1.00-5.00	38.4	1.03-1.18
	CuO/ EG	1.00-4.00	23.6	1.05-1.23
Wang et col (1999)	Al ₂ O ₃ / Eau	3.00-5.50	28	1.11-1.16
	CuO/ Eau	4.50-9.70	23	1.17-1.34
	Al ₂ O ₃ / EG	5.00-8.00	28	1.25-1.41
	CuO/ EG	6.2-14.80	23	1.24-1.54
	Al ₂ O ₃ / H M	2.25-7.40	28	1.05-1.30
Xie et col (2002b)	Al ₂ O ₃ / Eau	1.80-5.00	60.4	1.07-1.21
	Al ₂ O ₃ /EG	1,80-5.00	15	1.06-1.17
	Al ₂ O ₃ /EG	1,80-5.00	26	1.06-1.18
	Al ₂ O ₃ /EG	1,80-5.00	60.4	1.08-1.30
	Al ₂ O ₃ /EG	1,80-5.00	302	1.39-1.25
Xie et col (2002c)	Al ₂ O ₃ / Eau	5.00	60.4	1.23
	Al ₂ O ₃ /EG	5.00	60,4	1.29
Wen et Ding (2004)	Al ₂ O ₃ / Eau	0.19–1.59	42	1.01–1.10
Murshed et col (2005)	TiO ₂ / Eau	0.50–5.00	15	1.05–1.30
	TiO ₂ / Eau	0.50–5.00	10 × 40	1.08–1.33
Wen et Ding (2005)	Al ₂ O ₃ / Eau	0.31–0.72		1.02–1.06
Hwang et col (2006)	CuO/ Eau	1.00		1.05
	SiO ₂ / Eau	1.00		1.03
	CuO/ EG	1.00		1.09
Kang et col (2006)	SiO ₂ / Eau	1.00–4.00	15–20	1.02–1.05
Lee et col (2006)	CuO/ Eau (pH = 3)	0.03–0.30	25	1.04–1.12
	CuO/ Eau (pH = 6)	0.03–0.30	25	1.02–1.07
Wen et Ding (2006)	TiO ₂ / Eau (pH = 3)	0.29–0.68	34	1.02–1.06

Tableau II.2 : Effet de la température et de la taille des particules sur la conductivité thermique [1].

Auteur (Année)	Nanofluide	La concentration	La taille	L'amélioration
Masuda et col (1993)	Al ₂ O ₃ / Eau (31.85°C)	1,30-4.30	13	1.109-1.324
	Al ₂ O ₃ / Eau (46.85°C)	1.30-4.30	13	1.100-1.296
	Al ₂ O ₃ / Eau (66.85°C)	1.30-4.30	13	1.092-1.262
	SiO ₂ / Eau (31.85°C)	1.10-2.30	12	1.010-1.011
	SiO ₂ / Eau (46.85°C)	1.10-2.30	12	1.009-1.010
	SiO ₂ / Eau (66.85°C)	1.10-2.40	12	1.005-1.007
	TiO ₂ / Eau (31.85°C)	3.25-4.30	27	1.080-1.105
	TiO ₂ / Eau (46.85°C)	3.25-4.30	27	1.084-1.080
	TiO ₂ / Eau (86.85°C)	3.10-4.30	27	1.075-1.099
Das et col (2003)	Al ₂ O ₃ / Eau (21°C)	1.00–4.00	38.4	1.02–1.09
	Al ₂ O ₃ / Eau (36°C)	1.00–4.00	38.4	1.07–1.16
	Al ₂ O ₃ / Eau (51°C)	1.00–4.00	38.4	1.10–1.24
	CuO/ Eau (21°C)	1.00–4.00	28.6	1.07–1.14
	CuO/ Eau (36°C)	1.00–4.00	28.6	1.22–1.26
	CuO/ Eau (51°C)	1.00–4.00	28.6	1.29–1.36
Li et Peterson (2006)	Al ₂ O ₃ / Eau (27.5°C)	2.00–10.00	36	1.08–1.11
	Al ₂ O ₃ / Eau (32.5°C)	2.00–10.00	36	1.15–1.22
	Al ₂ O ₃ / Eau (34.7°C)	2.00–10.00	36	1.18–1.29
	CuO/ Eau (28.9°C)	2.00–6.00	29	1.35–1.36
	CuO/ Eau (31.3°C)	2.00–6.00	29	1.35–1.50
	CuO/ Eau (33.4°C)	2.00–6.00	29	1.38–1.51

b. Les métaux et carbone silicone

Tableau II.3 : Effet de la température et de la taille des particules sur la conductivité thermique [1].

Auteur (Année)	Nanofluide	La concentration	La taille	L'amélioration
Patel et Col (2003)	Ag/ Eau (30°C)	0.001	60–70	1.030
	Ag/ Eau (60°C)	0.001	60–70	1.04
	Au/ Eau (30°C)	0.00013	10–20	1.03
	Au/ Eau (60°C)	0.00013	10–20	1.05
	Au/ Eau (30°C)	0.00026	10–20	1.05
	Au/ Eau (60°C)	0.00026	10–20	1.08
Wen and Ding (2004)	MWCNT/eau (20°C)	0.04–0.84	20–60 (D)	1.04–1.24
	MWCNT/eau (45°C)	0.04–0.84	20–60 (D)	1.05–1.31
Ding et Col (2006)	MWCNT/eau (20°C)	0.05–0.49		1.00–1.10
	MWCNT/eau (25°C)	0.05–0.49		1.07–1.27
	MWCNT/eau (30°C)	0.05–0.49		1.18–1.79

Tableau II.4 : Effet de la taille des particules sur la conductivité thermique [1].

Auteur (Année)	Nanofluide	La concentration	Taille de la particule	L'amélioration
Xuan et Li (2000)	Cu / Eau	2.50-7.50	100	1.22 -1.75
Eastman et Col (2001)	Cu/EG	0.10-0.56	<10	1.016-1.100
	Cu /EG	0.11-0.56	<10	1.031-1.140
	Cu /EG	0.01-0.28	<10	1.002-1.140
Xie, et Col (2002a)	SiC/ Eau	0.78-4.18	26	1.03 -1.17
	SiC/ Eau	1.00-4.00	600	1.06 -1.24
	SiC/EG	0.89-3.50	26	1.04 -1.13
	SiC/EG	1.00-4.00	600	1.06 -1.23
Xie et Col (2003)	MWCNT/ eau	0.40–1.00	15 nm×30µm	1.03–1.07
	MWCNT/ EG	0.23–1.00	15 nm×30µm	1.02–1.13
Assael et Col(2004)	MWCNT/eau	0.60	100 nm×50µm	1.07–1.38
Assael et Col (2005)	DWCNT/eau	0.75	5 (D)	1.03
	DWCNT/eau	1.00	5 (D)	1.08
	MWCNT/eau	0.60	130 nm×10µm	1.34
	MWCNT/eau	0.60	130 nm×10µm	1.28
Hong et Col (2005)	Fe/EG	0.20–0.55	10	1.13–1.18
Liu et Col (2005)	MWCNT/EG	0.20–1.00	20–50 (D)	1.02–1.12
	MWCNT/H M	1.00–2.00	20–50 (D)	1.09–1.30
Hong et Col (2006)	Fe/ EG	0.10–0.55	10	1.05–1.18
Hwang et Col (2006)	MWCNT/ Eau	1.00		1.07
	MWCNT/ H Min	0.50		1.09
Kang et Col (2006)	Ag/ Eau	0.10–0.39	8–15	1.03–1.11
	Diamant/EG	0.13–1.33	30–50	1.03–1.75
Liu et Col (2006)	Cu/ Eau	0.05		1.04
	Cu/ Eau	0.10	50–100	1.24
	Cu/ Eau	0.10	75–100	1.24
	Cu/ Eau	0.05	100–200	1.12
	Cu/ Eau	0.10	100–300	1.11
	Cu/ Eau	0.05	130–200	1.09
	Cu/ Eau	0.20	130–300	1.10
	Cu/ Eau	0.20	250	1.04
	Cu/ Eau	0.20	200 × 500	1.13

EG : Ethylène glycol, H M : Huile de moteur, H Min : Huile minérale.

III. Exemples des types de règles d'apprentissage

Des exemples d'utilisations de différentes règles d'apprentissage, d'architectures et d'algorithmes qui sont reliés à des types supervisés et non supervisés sont illustrés dans les tableaux III.1 et III.2

Tableau III.1 : Exemple de différents types d'apprentissages en mode supervisé [8].

<i>Paradigme</i>	<i>Architecture</i>	<i>Règle d'apprentissage</i>	<i>Algorithme</i>	<i>Taches</i>
<i>Supervisé</i>	Perceptron Simple ou Multi-Couches	Correction d'erreur	Perception Rétro-Propagation, Adaline, Madaline	Classification Approximation de fonctions, Prédiction, Contrôle
	Récurrente	Boltzmann	Apprentissage de Boltzmann	Classification
	Multi-Couches non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données Classification
	à compétition	Par compétition	LVQ	Catégorisation au sein d'une classe Compression de données
	ART		ARTMap	Classification Catégorisation au sein d'une classe

Tableau III.2 : Exemple de différents types d'apprentissages en mode non supervisé [8].

<i>Paradigme</i>	<i>Architecture</i>	<i>Règle d'apprentissage</i>	<i>Algorithme</i>	<i>Taches</i>
<i>Non Supervisé</i>	Multi-Couches non bouclés	Correction d'erreur	Projection de Sammon	Analyse de données
	Non bouclés ou à compétition	Hebb	Analyse en composantes	Analyse de données
	à compétition	Par compétition	VQ	Catégorisation, Compression de données
	Carte de Kohonen		SOM	Catégorisation, Analyse de données
	ART		ART-1, ART-2	Catégorisation

IV. Références

- [1] Yu, W., France, D. M., Routbort, J. L., Choi, S. U. (2008). Review and comparison of nanofluid thermal conductivity and heat transfer enhancements. *Heat transfer engineering*, 29(5), 432-460.
- [2] Das, S. K., Putra, N., Thiesen, P., Roetzel, W. (2003). Temperature dependence of thermal conductivity enhancement for nanofluids. *J. Heat Transfer*, 125(4), 567-574.
- [3] Teng, T. P., Lin, L., Yu, C. C. (2013). Preparation and Characterization of Carbon Nanofluids by Using a Revised Water-Assisted Synthesis Method. *Journal of Nanomaterials*, 2013, 37-48.
- [4] SEZER, Ö. S., YAZICIOĞU, A. G., KAKAC, S. (2010). Convective heat transfer enhancement with nanofluids: the effect of temperature-variable thermal conductivity. In *Engineering Systems Design and Analysis*, 49163, 719-731.
- [5] Bažant, Z. P. (2000). Size effect. *International Journal of Solids and Structures*, 37(1-2), 69-80.
- [6] Xie, H., Wang, J., Xi, T., Liu, Y., Ai, F., Wu, Q. (2002). Thermal conductivity enhancement of suspensions containing nanosized alumina particles. *Journal of applied physics*, 91(7), 4568-4572.
- [7] Timofeeva, E. V., Routbort, J. L., & Singh, D. (2009). Particle shape effects on thermophysical properties of alumina nanofluids. *Journal of applied physics*, 106(1), 014304.
- [8] Brakni, E. M. (2011). Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM, Doctoral dissertation, Université du Québec en Abitibi-Témiscamingue, Canada.

1. Propriétés et prétraitement des données utilisées dans le chapitre IV

Les propriétés thermophysiques utilisées dans le chapitre IV pour les nanoparticules d' Al_2O_3 et le fluide de base (Eau) ainsi que le nanofluide $\text{Al}_2\text{O}_3/\text{Eau}$ sont présentées dans les tableaux 1 et 2.

Tableau 1: Propriétés de l'eau pure, de particule et de nanofluide $\text{Al}_2\text{O}_3/\text{Eau}$ [1].

<i>Propriétés</i>	<i>Eau pure</i>	<i>Propriétés de particule Al_2O_3</i>	<i>Propriétés de Nanofluide</i>
<i>Densité, ρ (kg/m^3)</i>	987,17	3600	989,78283
<i>Chaleur spécifique, c_p ($\text{J}/\text{kg}\cdot\text{K}$)</i>	4182	765	4169,571819
<i>Conductivité thermique, k ($\text{W}/\text{m}\cdot\text{K}$)</i>	0,645	36	0,646836333
<i>Viscosité dynamique, μ (Ns/m^2)</i>	0,000528	0	0,122426401
<i>Coefficient de dilatation thermique, β ($1/\text{K}$)</i>	0,0004712	0,0000058	0,000469507
<i>Conductivité thermique, k ($\text{W}/\text{m}\cdot\text{K}$), Statique</i>	/	/	0,646836333
<i>Conductivité thermique, k ($\text{W}/\text{m}\cdot\text{K}$), Brwonain</i>	/	/	0,122426401

Tableau 2 : Variables de calcul pour $\text{Al}_2\text{O}_3/\text{Eau}$ [1].

<i>Variables calculassions</i>	<i>valeurs</i>
\emptyset	0,001
dp	2,00E-08
<i>Fraction de volume de liquide, β pour Al_2O_3</i>	99,86618619
<i>Température (K)</i>	325
$f(T, \emptyset)$	0,000752209
<i>constante de Boltzmann J/K</i>	1,38E-23
<i>Poids moléculaire du fluide de base, M (kg/mol)</i>	0,01801528
<i>Masse volumique de l'eau at 293k</i>	9,87E+02
<i>Numéro Avogadro, N (mol^{-1})</i>	6,02E+23
<i>Diamètre moléculaire de l'eau, df (m)</i>	3,86815E-10
<i>Diamètre hydraulique</i>	0,0203

On utilise un tableau nommé matrice d'expériences pour récapituler l'ensemble des essais. Les données expérimentales de conductivités thermiques effectives et de viscosités du nanofluide $\text{Al}_2\text{O}_3/\text{Eau}$ obtenues à partir de la littérature, sont présentées dans les tableaux 3 et 4 respectivement [1].

Tableau 3: Matrice de k_{nf}/k_f

x_1	x_2	x_3	x_4	$y_1: k_{nf}/k_f$
1	300	20	sphérique	1,11
1	300	40	sphérique	1,09
1	300	60	sphérique	1,077
1	300	80	sphérique	1,075
1	300	100	sphérique	1,069
2	300	20	sphérique	1,14
2	300	40	sphérique	1,11
2	300	60	sphérique	1,109
2	300	80	sphérique	1,1
2	300	100	sphérique	1,096
3	300	20	sphérique	1,169
3	300	40	sphérique	1,14
3	300	60	sphérique	1,136
3	300	80	sphérique	1,13
3	300	100	sphérique	1,125
4	300	40	sphérique	1,174
4	300	60	sphérique	1,167
4	300	80	sphérique	1,159
4	300	100	sphérique	1,155
5	300	20	sphérique	1,22
5	300	40	sphérique	1,2
5	300	60	sphérique	1,197
5	300	100	sphérique	1,186
1	300	20	lame	1,027
2	300	20	lame	1,059
3	300	20	lame	1,082
4	300	20	lame	1,11
5	300	20	lame	1,138
1	300	20	brique	1,03
2	300	20	brique	1,06
3	300	20	brique	1,1
4	300	20	brique	1,13
5	300	20	brique	1,17
1	300	20	cylindrique	1,04
2	300	20	cylindrique	1,08
3	300	20	cylindrique	1,12
4	300	20	cylindrique	1,159

5	300	20	cylindrique	1,2
1	300	20	plaquette	1,27
4	300	20	plaquette	1,11
1	300	20	sphérique	1,11
2	300	20	sphérique	1,14
3	300	20	sphérique	1,17
4	300	20	sphérique	1,2
5	300	20	sphérique	1,22
1	300	20	sphérique	1,13
2	300	20	sphérique	1,14
3	300	20	sphérique	1,17
4	300	20	sphérique	1,19
5	300	20	sphérique	1,23
1	305	20	sphérique	1,131
2	305	20	sphérique	1,15
3	305	20	sphérique	1,18
4	305	20	sphérique	1,22
5	305	20	sphérique	1,24
1	310	20	sphérique	1,15
2	310	20	sphérique	1,17
3	310	20	sphérique	1,2
4	310	20	sphérique	1,23
5	310	20	sphérique	1,26
1	315	20	sphérique	1,165
2	315	20	sphérique	1,192
3	315	20	sphérique	1,21
4	315	20	sphérique	1,25
5	315	20	sphérique	1,28
1	320	20	sphérique	1,18
2	320	20	sphérique	1,2
3	320	20	sphérique	1,23
4	320	20	sphérique	1,26
5	320	20	sphérique	1,3
1	325	20	sphérique	1,19
2	325	20	sphérique	1,22
3	325	20	sphérique	1,25
4	325	20	sphérique	1,28
5	325	20	sphérique	1,31
1	300	20	sphérique	1,117
1	300	40	sphérique	1,09
1	300	60	sphérique	1,08
1	300	80	sphérique	1,07
1	300	100	sphérique	1,07
2	300	20	sphérique	1,14
2	300	40	sphérique	1,117
2	300	60	sphérique	1,1

2	300	80	sphérique	1,1
2	300	100	sphérique	1,097
3	300	20	sphérique	1,16
3	300	40	sphérique	1,14
3	300	60	sphérique	1,138
3	300	80	sphérique	1,34
3	300	100	sphérique	1,126
4	300	20	sphérique	1,196
4	300	40	sphérique	1,17
4	300	60	sphérique	1,167
4	300	80	sphérique	1,163
4	300	100	sphérique	1,15
5	300	20	sphérique	1,22
5	300	40	sphérique	1,2
5	300	60	sphérique	1,2
5	300	80	sphérique	1,19
5	300	100	sphérique	1,186

Tableau 4: Matrice de μ_{nf}/μ_f

x_1	x_2	x_3	x_4	$y_2: \mu_{nf}/\mu_f$
1	300	20	sphérique	1,1
1	300	40	sphérique	1,092
1	300	60	sphérique	1,084
1	300	80	sphérique	1,075
1	300	100	sphérique	1,058
2	300	20	sphérique	1,23
2	300	40	sphérique	1,18
2	300	60	sphérique	1,16
2	300	80	sphérique	1,15
2	300	100	sphérique	1,13
3	300	20	sphérique	1,39
3	300	40	sphérique	1,3
3	300	60	sphérique	1,26
3	300	80	sphérique	1,24
3	300	100	sphérique	1,22
4	300	20	sphérique	1,64
4	300	40	sphérique	1,46
4	300	60	sphérique	1,38
4	300	80	sphérique	1,33
4	300	100	sphérique	1,32
5	300	20	sphérique	1,96
5	300	40	sphérique	1,66

5	300	60	sphérique	1,54
5	300	80	sphérique	1,47
5	300	100	sphérique	1,42
1	300	20	sphérique	1,1
2	300	20	sphérique	1,23
3	300	20	sphérique	1,4
4	300	20	sphérique	1,64
5	300	20	sphérique	1,95
1	300	40	sphérique	1,07
2	300	40	sphérique	1,18
3	300	40	sphérique	1,3
4	300	40	sphérique	1,46
5	300	40	sphérique	1,66
1	300	60	sphérique	1,07
2	300	60	sphérique	1,16
3	300	60	sphérique	1,26
4	300	60	sphérique	1,39
5	300	60	sphérique	1,53
1	300	80	sphérique	1,07
2	300	80	sphérique	1,14
3	300	80	sphérique	1,24
4	300	80	sphérique	1,34
5	300	80	sphérique	1,47
1	300	100	sphérique	1,057
2	300	100	sphérique	1,13
3	300	100	sphérique	1,21
4	300	100	sphérique	1,31
5	300	100	sphérique	1,42
1	300	20	lame	1,18
2	300	20	lame	1,53
3	300	20	lame	1,56
4	300	20	lame	1,77
5	300	20	lame	2,04
1	300	20	brique	1,16
2	300	20	brique	1,29
3	300	20	brique	1,45
4	300	20	brique	1,81
5	300	20	brique	2,31
1	300	20	cylindrique	1,22
2	300	20	cylindrique	1,66
3	300	20	cylindrique	2,22
4	300	20	cylindrique	2,97

5	300	20	cylindrique	3,93
1	300	20	plaquette	1,43
2	300	20	plaquette	1,97
3	300	20	plaquette	2,66
4	300	20	plaquette	3,45
5	300	20	plaquette	4,37
1	300	20	sphérique	1,08
2	300	20	sphérique	1,25
3	300	20	sphérique	1,41
4	300	20	sphérique	1,64
5	300	20	sphérique	1,95
1	300	20	sphérique	1,11
2	300	20	sphérique	1,23
3	300	20	sphérique	1,41
4	300	20	sphérique	1,64
5	300	20	sphérique	1,95
1	305	20	sphérique	0,84
2	305	20	sphérique	0,94
3	305	20	sphérique	1,07
4	305	20	sphérique	1,25
5	305	20	sphérique	1,5
1	310	20	sphérique	0,75
2	310	20	sphérique	0,83
3	310	20	sphérique	0,97
4	310	20	sphérique	1,12
5	310	20	sphérique	1,35
1	315	20	sphérique	0,68
2	315	20	sphérique	0,77
3	315	20	sphérique	0,89
4	315	20	sphérique	1,02
5	315	20	sphérique	1,21
1	320	20	sphérique	0,64
2	320	20	sphérique	0,69
3	320	20	sphérique	0,8
4	320	20	sphérique	0,93
5	320	20	sphérique	1,12
1	325	20	sphérique	0,56
2	325	20	sphérique	0,65
3	325	20	sphérique	0,74
4	325	20	sphérique	0,86
5	325	20	sphérique	1,03

Chaque forme est codifiée sous une forme numérique selon le tableau ci-dessous :

Tableau 5 : Codification de facteur x_4

<i>Forme de N_p</i>	<i>Codification</i>
<i>sphérique</i>	0
<i>lame</i>	0,25
<i>brique</i>	0,5
<i>cylindrique</i>	0,75
<i>plaquette</i>	1

2. Référence

- [1] Alawi, O. A., Sidik, N. A. C., Xian, H. W., Kean, T. H., Kazi, S. N. (2018). Thermal conductivity and viscosity models of metallic oxides nanofluids. Int J Heat Mass Transfer, 116, 1314-1325.

Communications nationales et internationales

✓ Communications internationales:

1. " Thermal conductivity modeling of oxide-water nanofluids using JMP ", The Third International Conference on "Research to Applications & Markets", Hammamet, Tunisia, September 16-18, 2016, <http://www.agendas.ovh/third-international-conference-on-research-to-app...>
2. "Using Design Of Experiments "DOE" In Modeling Of Effective Thermal Conductivity Of Nanofluids", the 4th International Conference on Pure and Applied Sciences Nov.23-25, 2017, Gelisim University, Istanbul, Turkey, <http://confs.naturalspublishing.com/icpas2017b/>
3. " Application of Artificial Neural Network (ANN) for the prediction of thermal conductivity and viscosity of alumina water-based nanofluids ", Vth International Conference on Energy, Materials, Applied Energetics and Pollution (ICEMAEP 2019), 22-24 October 2019, Constantine, Algeria.
<https://www.scribd.com/document/410910327/1st-Call-for-Papers-icemaep2019>
4. "Application of artificial neural network (ANN) for the prediction of nanofluids thermal conductivity" 6^{ème} JSFM-CMC 2019, 17-18 November 2019 - Annaba (Algérie), <http://www.jsfm-cmc.com/>

✓ Communications nationales:

1. First National Day on "Simulation and Nanomaterials", December 17, 2014, University Mai 8 1945 Guelma, Algeria. <http://www.univ-guelma.dz/fr/news-events/simulation-et-nanomat%C3%A9riaux...>
2. " Prediction of thermal conductivity of alumina water-based nanofluids using experimental data and artificial neural network " Journée Nationale « Etude des Matériaux: Elaboration et Modélisation », Dec.13, 2018, Guelma, Algeria. <http://www.univ-guelma.dz/fr/journ%C3%A9e-nationale-%C2%AB%C3%A9tude-des...>
3. " Predicting the effective thermal conductivity of Alumina/water and Alumina/Ethylene glycol nanofluids using artificial neural network ", 8^{èmes} Journées de Chimie Ecole Militaire Polytechnique (EMP) Chahid Abderrahmane Taleb Bordj El-Bahri, Algiers, Algeria. March 26-27, 2019. <http://www.emp.mdn.dz/events/jch/>

4. " Application of Artificial Neural Network for the prediction of oxide-based nanofluids dynamic viscosity ", 2nd Conference on Informatics and Applied Mathematics IAM'2019, 12-13 June 2019, Guelma, Algeria. <http://www.univ-guelma.dz/fr/2nd-conference-informatics-and-applied-math...>

Modeling the effective thermal conductivity of nanofluids using full factorial design analysis

Wassila Grine  | Mohamed E. H. Benhamza

Department of Process Engineering,
Laboratory of Industrial Analysis and
Materials Engineering, Faculty of
Sciences and Technology, University of
Guelma, Guelma, Algeria

Correspondence

Wassila Grine, Department of Process
Engineering, Laboratory of Industrial
Analysis and Materials Engineering,
Faculty of Sciences and Technology,
University of Guelma, BP 401, Guelma
24000, Algeria.

Email: grine.wassila@univ-guelma.dz
grinewassila@yahoo.fr

Abstract

In this paper, a full factorial design analysis is proposed for predicting nanofluid thermal conductivity ratio (TCR) as well as determining the effects of critical factors and their interactions. A statistical design of experiment approach with three variables (volume fraction, temperature, and nanoparticle diameter) at two levels is carried out. Three types of oxide-water nanofluids (Al_2O_3 -water, CuO-water, and TiO_2 -water) are used to evaluate the effectiveness of the proposed mathematical model. The significance and adequacy of the regression model were evaluated by the analysis of variance. The predicted model has a root mean square error equals to 0.0074, $R^2 = 0.99$, and $P < .0013$, thus showing good results compared to a set of experimental data as well as other mathematical model results. The results illustrate that the TCR of metallic oxide nanofluids increases with temperature and nanoparticles volume fraction but decreases when nanoparticle size intensifies. Furthermore, it is found that the nanoparticles volume fraction has a great impact on the nanofluids thermophysical properties. Finally, the obtained results confirm that the proposed model is considerably accurate and capable of predicting nanofluids thermal conductivity and that it can be used with ease as an alternative to many other models.

KEYWORDS

ANOVA, full factorial design, nanoparticle, oxide-water nanofluids, thermal conductivity

1 | INTRODUCTION

Over the last few decades, many researchers have been trying to find the appropriate technique to improve the heat transfer rate and to increase the thermal conductivity of fluids. One of the recent technologies of improving heat transfer is suspending nano-sized solid particles of metallic or oxide-metallic with high intrinsic thermal conductivity in a base fluid. This mixture is called a nanofluid.¹⁻⁵

Nanofluids thermophysical properties can be controlled by chemical and physical specifications of the base fluid and nanoparticles. Nanofluids thermal conductivity is one of the factors that play an important role in heat transfer performance. Thus, using a suitable type of nanofluids is highly important in improving the heat transfer rate.^{6,7} However, research results illustrate wide discrepancies and inconsistencies in nanofluids thermal conductivity due to different parameters, such as the difference in nanofluids production and stabilization techniques, nanofluids characterization as well as thermal conductivity measuring methods.⁸

A strong relationship exists between nanofluids thermal conductivity and various parameters, namely: nanoparticle volume fraction, particle material, size and shape, base fluid material and temperature, specific heat capacity, type of surfactant, and density.⁹⁻¹⁷

The overall aim of using nanofluids is to have optimum thermophysical properties at minimum particle volume fractions. Moreover, it has been reported that the thermal conductivity of nanofluids increases with the increase of nanoparticle concentration.^{7,18-20} It has also been revealed that the thermal conductivity enhancement ratio declines with that of the base fluid, while it is directly proportional to the nanoparticle thermal conductivity.^{21,22} Nevertheless, for a certain nanoparticles concentration, it is shown that for a lower thermal conductivity the heat transfer coefficient will be enhanced. This fact agrees with conventional models such as the Maxwell model. On the other hand, it has been shown by Alrashed et al.⁵ that nanofluids thermal conductivity enhancement is independent of the base fluid.

Another important factor that affects the nanofluids thermal conductivity is the nanoparticles' size, since it has been confirmed that the highest thermal conductivity is achieved by a uniform distribution of small particles.²¹ It is also assumed that an increase in the nanoparticles' specific surface area could lead to an increase in the effective nanofluids thermal conductivity because heat transfer between particles and the base fluid occur at particle/fluid interface. Moreover, the Brownian motion of nanoparticles could be intensified by reducing the particle's size. Hence, the latter is claimed to be one of the most important factors in enhancing nanofluids' heat transfer.^{21,23} The shape of nanoparticles is another parameter affecting the enhancement degree of nanofluids thermal conductivity.²⁴ The enhancement ratio of the elongated particles is greater than that of the spherical ones.²⁵ In general, a decrease in nanoparticle sphericity leads to an increase in nanofluids thermal conductivity.

Generally, nanofluids thermal conductivity is more sensitive to temperature and the increase in temperature ensued an increase of the thermal conductivity enhancement.^{4,20,26} Many studies showed the existence of an optimum temperature at which nanofluids thermal conductivity is maximum.⁷ Also the pH has an effect on the nanofluids thermal conductivity as its enhancement ratio increases with acidity.¹⁷ Furthermore, the thermal conductivity enhancement ratio can be affected by surfactants and additives used to prevent particle agglomeration.^{14,27} A summary of experimental studies on nanofluids thermal conductivity can be found in Rashmi et al.²⁸

From the above review, it can be noticed that all the different parameters and mechanisms affecting the thermal conductivity of nanofluids cannot be accounted by the traditional models

TABLE 1 Summary of representative studies on thermal conductivity of water-based nanofluids adopted in this study

Nanoparticle	Particle volume fraction (%)	Particle size, nm	Temperature, K	Researchers
CuO	0-18	29, 28.6	Room temperature	Aminian ³⁴
Al ₂ O ₃	1-4	20, 25, 28		
CuO	0-5	28.5	Different temperature	Kazemi-Beydokhti et al ³⁵
Al ₂ O ₃	0-5	20, 25		
TiO ₂	0.2-2	21	288-308	Duangthongsuk et al ³⁶
TiO ₂	0-8	21	288-338	Yiamsawasd et al ³⁷
Al ₂ O ₃	1-4	30 ± 10	274-313	Longo et al ³⁸
TiO ₂	1-6	30-50 ± 10		

of particle suspensions.²⁰ Thus, several models have been proposed, such as the work of Alrashed et al^{5,29} using an enhanced artificial neural network (EANN) and an adaptive neuro-fuzzy inference system approach and the results showed a suitable accuracy with experimental data. Hosseini et al⁹ presented a nanofluid thermal conductivity model as a function of nanoparticle thermal conductivity, taking into consideration the working fluid, temperature, nanoparticle volume fraction, and size as well as the properties of the interfacial shell. Their results demonstrated good compatibility with experimental data and other models. Shahsavari et al³⁰ explored several experiments with the artificial neural network method to measure and model nanofluid thermal conductivity and viscosity. The results of their model can be employed to provide the calculation of properties. Bagherzadeh et al³¹ developed an EANN approach of nanofluid thermal conductivity. Their proposed model gave accurate results with less computational time. A complete review of these models can be found in references.^{32,33}

Due to wide discrepancies and inconsistencies results shown in literature, additional investigations to elucidate nanofluids thermal conductivity effects must be carried out. Thus, the present research work aims to find a new correlation that takes into account all the parameters influencing the thermal conductivity by using expanded and extensive experimental data.

Therefore, in this study, a mathematical model is developed to predict the thermal conductivity of oxide-water nanofluids. Four major influencing factors on the nanofluid thermal conductivity have been selected, and design of experiment (DOE) with the analysis of variance (ANOVA) method are used to determine the effects of these factors and their interactions. A full factorial method is considered at two levels for each factor,² and the results

TABLE 2 Thermophysical properties of water and selected nanoparticles

		μ , kg/m·s	ρ , kg/m ³	C_p , J/kg·K	K , W/m·K
Base fluid	Water (H ₂ O)	0.000912	997.047	4184	0.6063
Nanoparticles	Alumina (Al ₂ O ₃)	...	3970	765	40
	Titanium dioxide (TiO ₂)	...	4250	686.2	8.9538
	Copper oxide (CuO)	...	6500	535.6	20

TABLE 3 Factors and levels used in the factorial design

Factors	Low level (-1)	High level (+1)
(X_1) Particle volume fraction (%)	1	4
(X_2) Temperature, K	295	298
(X_3) Particle size, nm	21	29

are analyzed and plotted by DOEs software. The present modeling is based on experimental data collected from the literature and the predicted results were compared to those of other models as well as with experimental results.

The novelty of the present work is that it only uses significant factors, thus needing less experimental data and computational time. Furthermore, operating conditions of the present research work are at low temperature and medium volume fraction, while the majority of the empirical and statistical models in use, are applicable at higher temperature ranges. Hence, the purpose of this study is to formulate a new model for predicting the thermal conductivity of three types of nanofluids at low temperatures and medium volume fractions.

2 | EXPERIMENTAL DATA

The experimental data used in this study are extracted from literature³⁴⁻³⁸; the details are presented in Table 1. Metal oxide nanoparticles are used in the present work because they are the most employed in heat transfer applications due to their low cost. They are produced by conventional methods and are more stable than metallic nanoparticles.³⁹ Three types of oxide metal nanoparticles are studied: Aluminum oxides (Alumina), Al_2O_3 ⁴⁰; Titanium oxides (Titania), TiO_2 ; and Copper oxides, CuO .^{41,42} The corresponding thermophysical properties of the base fluid (water)⁴³ and solid phases are given in Table 2.

3 | FULL FACTORIAL DESIGNS

A full factorial design is a powerful technique, quick and cost-effective, employed to achieve the best optimization. This design allows us to determine the effects on the response of each of the factor levels. Furthermore, it takes into consideration all the combinations between factors' levels as well as the effects of interactions between different factors. This technique is used to reduce the number of experiments, time and overall process cost with a better response. The importance of this method is shown by different studies using experimental designs.^{44,45}

4 | MATHEMATICAL MODEL

In this study, an experimental design method is adopted to optimize nanofluids thermal conductivity. The DOE technique is performed to identify the key variables that affect the thermal conductivity ratio (TCR; K_{nf}/K_f) and to determine at what levels these factors must be kept to reduce measurement errors. The full factorial design method is used to study the effects caused by

independent factors as well as interactions between those self-governing factors.^{46,47} In the present work, a full factorial design at two levels for three independent factors is considered: volume fraction (X_1), temperature (X_2), and nanoparticle diameter (X_3), with two factorial levels coded as -1 , $+1$, for low and high levels, respectively. The types of the nanoparticles (X_4) are coded as L_1 for (Al_2O_3), L_2 for (TiO_2), and L_3 for (CuO). A full factorial design 2^3 (ie, three factors are varied over two levels) for three types of nanoparticles is utilized. Therefore, a total of 24 experimental runs are suggested for analyzing the interaction of each level (Table 4). The ratio (K_{nf}/K_f) is considered as the response factor (dependent factor). Results are analyzed and plotted with 95% confidence intervals using experimental design software.

The polynomial equation for the experimental design with three factors is given by the following Equation (1):

$$y = a_0 + \sum a_i x_i + \sum a_{ij} x_i x_j + \dots + \sum a_{ii} x_i^2 + a_{ij\dots z} x_i x_j \dots x_z + e \quad (1)$$

TABLE 4 Design matrix and the experimental responses

Nanoparticles	Experiment	Independent factors				Dependent factors
		X_1	X_2	X_3	X_4	
		ϕ	T	dp	Np	$Y = K_{nf}/K_f$
Al_2O_3	01	-1	-1	-1	L1	1.017
	02	1	-1	-1	L1	1.09
	03	-1	1	-1	L1	1.02895
	04	1	1	-1	L1	1.100320
	05	-1	-1	1	L1	1.0257
	06	1	-1	1	L1	1.093
	07	-1	1	1	L1	1.025400
	08	1	1	1	L1	1.105400
TiO_2	09	-1	-1	-1	L2	1.052300
	10	1	-1	-1	L2	1.096330
	11	-1	1	-1	L2	1.047505
	12	1	1	-1	L2	1.130000
	13	-1	-1	1	L2	1.047070
	14	1	-1	1	L2	1.111920
	15	-1	1	1	L2	1.018215
	16	1	1	1	L2	1.115060
CuO	17	-1	-1	-1	L3	1.057
	18	1	-1	-1	L3	1.154
	19	-1	1	-1	L3	1.136
	20	1	1	-1	L3	1.16
	21	-1	-1	1	L3	1.05835
	22	1	-1	1	L3	1.088200
	23	-1	1	1	L3	1.0609
	24	1	1	1	L3	1.110300

Independent factors: is the factor that is changed or controlled in the experiment, in this study three independent factors is considered: volume fraction (ϕ), temperature (T) and particle size (dp) which are coded X_1 , X_2 and X_3 respectively. Np: is the types of the nanoparticles (X_4) are coded as L_1 for (Al_2O_3), L_2 for (TiO_2) and L_3 for (CuO). Dependent factors: is the variable that is being measured or tested in an experiment, in this study the thermal conductivity ratio (K_{nf}/K_f) is considered as the response factor (dependent factor) which coded by Y.

TABLE 5 Constants values

Nanoparticles	Constants						
	$C_1 \times 10^{-4}$	$C_2 \times 10^{-4}$	$C_3 \times 10^{-4}$	$C_4 \times 10^{-4}$	$C_5 \times 10^{-4}$	$C_6 \times 10^{-4}$	$C_7 \times 10^{-4}$
Al ₂ O ₃	39.52	-18.36	103.99	2.13	5.18	-23.92	-196.5
TiO ₂	35.21	-57.37	45.16	76.37	45.48	-49.92	-30.71
CuO	-74.74	75.73	-149.1	-78.51	-50.66	73.85	227.22

Where y is the response of a domain determined experimentally with a definite accuracy, x is the i th variable or a reduced centered coordinate; a_0, a_b, a_{ij}, a_{ii} are model coefficients determined experimentally and e is the total standard deviation including the experimental and model selection errors. Tables 3 and 4 show the selected four factors and different factor level settings as well as the obtained response matrix at each run. A convenient selection of the experimental domain allows to cover the required optimal zone.

5 | RESULTS AND DISCUSSION

The mathematical model generated by the experimental design method, obtained on the basis of experimental data has the following polynomial form:

$$\begin{aligned}
 Y = & 1.083716666 + (0.032505833 + C_1)X_1 + (0.0061325 + C_2)X_2 \\
 & + (-0.008745416 + C_3)X_3 + (-0.005212916)X_2X_3 \\
 & + (C_4)X_1X_2 + (C_5)X_1X_3 + (0.00418375 + C_6)X_1X_2X_3 + C_7.
 \end{aligned} \quad (2)$$

Where $X_1 = \frac{\phi - 0.025}{0.015}$, $X_2 = \frac{T - 296.5}{1.5}$, $X_3 = \frac{d_p - 0.000000025}{0.000000004}$, and $C_1, C_2, C_3, C_4, C_5, C_6,$ and C_7 are constants depending on the type of nanoparticle determined by its physical properties. The values of these constants for each nanoparticle are given in Table 5.

The partial models of each of the three types of nanofluids are as follows:

$$\begin{aligned}
 \text{Al}_2\text{O}_3: Y = & 1.0640665 + 0.036458749X_1 + 0.00429625X_2 + 0.00165375X_3 - 0.005212916X_2X_3 \\
 & + 0.00021375X_1X_2 + 0.000518333X_1X_3 + 0.00179125X_1X_2X_3.
 \end{aligned} \quad (3)$$

$$\begin{aligned}
 \text{TiO}_2: Y = & 1.080645 + 0.036027499X_1 + 0.000395X_2 - 0.0039375X_3 - 0.005212916X_2X_3 \\
 & + 0.0076375X_1X_2 + 0.004548333X_1X_3 - 0.00080875X_1X_2X_3.
 \end{aligned} \quad (4)$$

$$\begin{aligned}
 \text{CuO}: Y = & 1.106438749 + 0.02503125X_1 + 0.01370625X_2 - 0.023656249X_3 - 0.005212916X_2X_3 \\
 & - 0.00785125X_1X_2 - 0.005066666X_1X_3 + 0.0115675X_1X_2X_3.
 \end{aligned} \quad (5)$$

5.1 | Testing of the proposed model

The proposed model is tested by comparing the TCR (K_{nf}/K_f) of the predicted values with the actual values, taking into account the standard error (Figure 1).

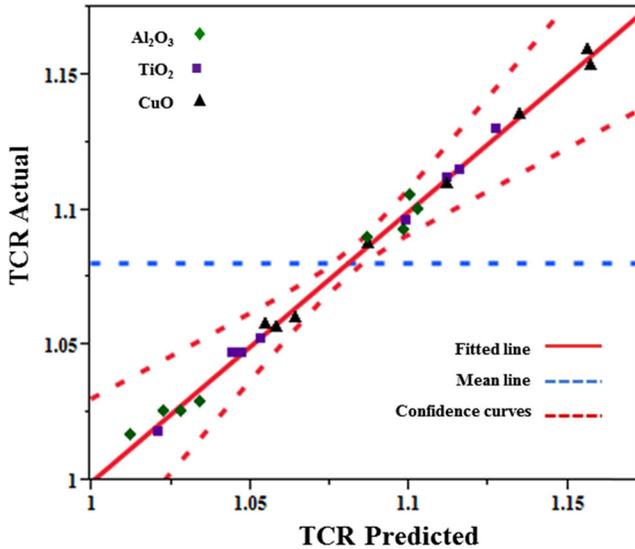


FIGURE 1 Actual and predicted values, for TCR models. ($P = .0013$; $R^2 = 0.99$; $RMSE = 0.0074$). RMSE, root mean square error [Color figure can be viewed at wileyonlinelibrary.com]

It is clearly shown that all the values of TCR are within the central line, with a value of root mean square error of (0.0074). Furthermore, the TCR model provides a good correlation between predicted and experimental values with R^2 equals to 0.99.

Table 6 gives the estimated parameters and their standard errors and the corresponding t test to each value of the independent variable. The obtained results show that all of the standard errors are very small (<0.003), which indicates that the results are statistically significant. The ANOVA for the full factorial design of the polynomial model is presented in Table 7. It can be noticed that the proposed model is significant with a P value of .0013. Besides, the confidence level for linear terms X_1 ($P < .0001$), X_3 ($P < .0045$), and X_4 ($P < .0008$) are most significant on TCR, while X_2 ($P < .0157$) is significant. Most of the square terms and their interactions are also highly significant. Likewise, it can be seen from Table 7 that the particle volume fraction is the most significant term since it has a very high F value. Hence, the particle volume fraction has the most significant effect factor on the thermal conductivity enhancement ratio. The particle diameter is also an important factor (with high F value). Although the temperature term has a lower F value compared to other main parameters, an F value of 16.26 suggests that the temperature has also a significant effect on the response. In addition, R^2 and adjusted R^2 values of 0.99 and 0.97, respectively, are very close to 1, suggesting a strong relationship between variables and the higher correlation between experimental and fitted values. This confirms that the proposed model has excellent predictive capability.

Figure 2 shows the profiles of the predicted response TCR vs the four factors: (ϕ , T , dp , and N_p), coded X_1 , X_2 , X_3 , and X_4 , respectively. They indicate that the volume fraction (ϕ) and the temperature (T) have a positive effect on the response. These results signify that TCR increases when X_1 and X_2 change from a lower level to a higher level. On the other hand, the particle size (dp) has a negative effect on the response. This means that the response reduces when this factor passes from low levels to high levels. Thus, it can be confirmed that CuO is the preminent nanoparticle used to increase the TCR response.

TABLE 6 Prediction parameter estimates

Term	Estimation	Std error	t Ratio	P > t
Intercept value a_0	1.08037167	0.00152043	710.57	<.0001*
X_1 (0.01, 0.04)	0.03250583	0.00152043	21.38	<.0001*
X_2 (295, 298)	0.0061325	0.00152043	4.03	.0157*
X_3 (2.1e-8, 2.9e-8)	-0.00874542	0.00152043	-5.75	.0045*
X_4 [L1]	-0.01965042	0.00215021	-9.14	.0008*
X_4 [L2]	-0.00307167	0.00215021	-1.43	.2263
X_4 [L3]	0.02272208	0.00215021	10.57	.0005*
$X_1 \times X_4$ [L1]	0.00395292	0.00215021	1.84	.1399
$X_1 \times X_4$ [L2]	0.00352167	0.00215021	1.64	.1768
$X_1 \times X_4$ [L3]	-0.00747458	0.00215021	-3.48	.0254*
$X_2 \times X_3$	-0.00521292	0.00152043	-3.43	.0266*
$X_2 \times X_4$ [L1]	-0.00183625	0.00215021	-0.85	.4412
$X_2 \times X_4$ [L2]	-0.0057375	0.00215021	-2.67	.0559
$X_2 \times X_4$ [L3]	0.00757375	0.00215021	3.52	.0244*
$X_3 \times X_4$ [L1]	0.01039917	0.00215021	4.84	.0084*
$X_3 \times X_4$ [L2]	0.00451167	0.00215021	2.1	.1039
$X_3 \times X_4$ [L3]	-0.01491083	0.00215021	-6.93	.0023*
$X_1 \times X_2 \times X_4$ [L1]	0.00021375	0.00215021	0.1	.9256
$X_1 \times X_2 \times X_4$ [L2]	0.0076375	0.00215021	3.55	.0238*
$X_1 \times X_2 \times X_4$ [L3]	-0.00785125	0.00215021	-3.65	.0217*
$X_1 \times X_3 \times X_4$ [L1]	0.00051833	0.00215021	0.24	.8214
$X_1 \times X_3 \times X_4$ [L2]	0.00454833	0.00215021	2.12	.1019
$X_1 \times X_3 \times X_4$ [L3]	-0.00506667	0.00215021	-2.36	.078
$X_1 \times X_2 \times X_3$	0.00418375	0.00152043	2.75	.0513
$X_1 \times X_2 \times X_3 \times X_4$ [L1]	-0.0023925	0.00215021	-1.11	.3282
$X_1 \times X_2 \times X_3 \times X_4$ [L2]	-0.0049925	0.00215021	-2.32	.081
$X_1 \times X_2 \times X_3 \times X_4$ [L3]	0.007385	0.00215021	3.43	.0264*

*Significant at $P \leq .05$.

Maximizing desirability is performed to obtain optimal factor settings for a maximum TCR. The profiler in Figure 3 displays the following optimal settings: 0.042 for volume fraction, 294.73K for temperature, 21.27 nm for particle diameter, and CuO for the nanoparticle type, thus giving an estimated response equals to 1.162.

5.2 | Validation of the proposed model

To validate the proposed model of nanofluids conductivity ratio, a comparison with experimental and theoretical models results is performed. Figures 4-9 show the effects of different parameters on the nanofluids TCR of experimental data set compared with the proposed model.

TABLE 7 Analysis of variance ANOVA results for experimental design

source	SS	DF	MS	F value	P > F
Model	0.04270618	19	0.0022477	40.5130	.0013*
X_1 (0.01, 0.04)	0.02535910	1	0.0253591	457.0790	< .0001*
X_2 (295, 298)	0.00090258	1	0.0009026	16.2684	.0157*
X_3 (2.1e-8, 2.9e-8)	0.00183558	1	0.0018356	33.0849	.0045*
X_4	0.00729494	2	0.0036475	65.7429	.0009*
$X_1 \times X_4$	0.00067118	2	0.0003356	6.0487	.0617
$X_2 \times X_3$	0.00065219	1	0.0006522	11.7552	.0266*
$X_2 \times X_4$	0.00074922	2	0.0003746	6.7521	.0522
$X_3 \times X_4$	0.00280665	2	0.0014033	25.2939	.0054*
$X_1 \times X_2 \times X_4$	0.00096015	2	0.0004801	8.6530	.0352*
$X_1 \times X_3 \times X_4$	0.00037302	2	0.0001865	3.3617	.1391
$X_1 \times X_2 \times X_3$	0.00042009	1	0.0004201	7.5718	.0513
$X_1 \times X_2 \times X_3 \times X_4$	0.00068150	2	0.0003407	6.1418	.0603
Residual	0.00022192	4	0.0000555
Total	0.04292811	23
R^2	0.99483035
Adj R^2	0.97027453

Abbreviations: DF, degree of freedom; MS, mean square; SS, sum of square.

*Significant at $P \leq .05$.

The effect of volume fractions on the predicted TCR with different diameters of nanoparticles of CuO-water nanofluids and at temperatures of 295K and 298K are given in Figure 4A,B, respectively. As it can be seen in these figures, the proposed model is in good agreement with the experimental data which are extracted from Aminia,³⁴ Zerradi et al,⁴⁸ and Khedkar et al.⁴⁹

Figure 5A shows the proposed model's ability to predict the TCR of Al_2O_3 -water nanofluid at 298K, compared with the experimental data.³⁵ Thus, the proposed model has an accurate prediction of the TCR for different particle volume fractions.

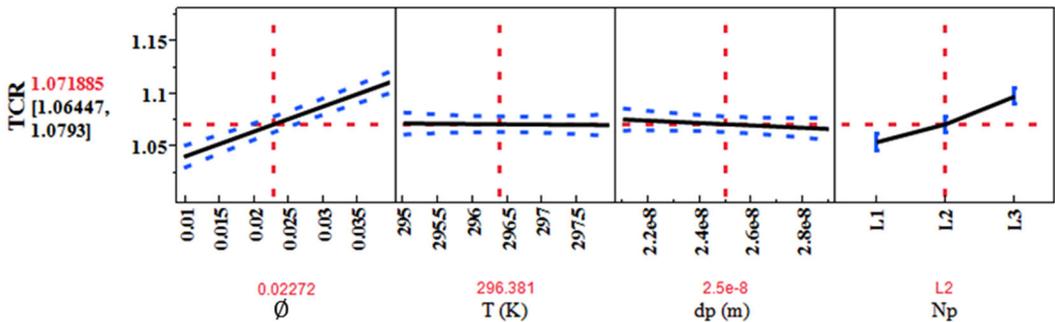


FIGURE 2 Predict TCR vs $X_1(\phi)$, $X_2(T)$, $X_3(dp)$, and $X_4(Np)$ (Red lines, predicted TCR; blue lines, 95% confidence interval of the mean TCR). TCR, thermal conductivity ratio [Color figure can be viewed at wileyonlinelibrary.com]

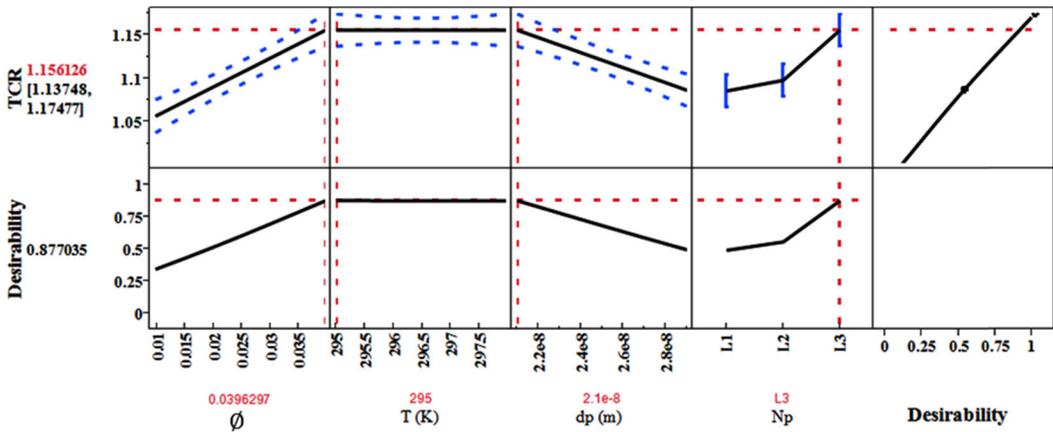


FIGURE 3 Prediction profiles at the optimum settings. TCR, thermal conductivity ratio [Color figure can be viewed at wileyonlinelibrary.com]

Similarly, Figure 5B illustrates a good agreement of the TCR of TiO₂-water nanofluid of the proposed model compared with the experimental data of Duangthongsuk and Wongwises,³⁶ Yiamsawasd et al,³⁷ and Zerradi et al⁴⁸ at the same conditions of temperature and volume fraction for different nanoparticles diameters.

The effects of temperature variation (T) on the nanofluids TCR of CuO-water and Al₂O₃-water for nanoparticles diameter of 29 nm are presented in Figure 6A,B, respectively. The predictions of the TCR of the proposed model are within an acceptable accuracy for an available experimental data.³⁴

Results are shown in Figure 7 of CuO-water nanofluids TCR at an ambient temperature of our proposed model are compared to experimental results, that are extracted from Aminia³⁴ as well as to correlations developed by Chon et al,⁵⁰ Koo and Kleinstreuer,⁵¹ and Li and Peterson,⁵² Hamilton-Crosser classical model⁵³ and to a neural model.³⁴ As it can be seen, the proposed model provides a better matching than the results obtained by Li and Peterson,⁵² Koo and Kleinstreuer,⁵¹ and neural models³⁴. Similarly, the correlation developed by Chon et al⁵⁰ fits well the experimental data. Furthermore, one can notice that the Hamilton-Crosser relationship provides good results for small values of the particle volume fraction.

In our proposed model, the variation of nanofluids TCR as a function of temperature is compared to the results of various correlations as well as to data set of Aminia,³⁴ and that is for CuO in the water of a 29 nm diameter and particle volume fraction of 4% (Figure 8). As it can be clearly seen, the proposed model generates a better fitting with experimental data. Nevertheless, both relationships developed by Koo and Kleinstreuer⁵¹ and Chon et al⁵⁰ present relatively fine results. In contrary, Li and Peterson⁵² model cannot predict well the thermal conductivity enhancement trend of the experimental results of Aminia³⁴. It is also interesting to note that the Hamilton-Crosser model⁵³ remains an acceptable prediction of nanofluids effective thermal conductivity at least at ambient temperatures.

Figure 9 depicts a comparison between the thermal conductivity obtained from experiments and that obtained from the present model. The experimental data sets used in this figure are from Kazemi-Beydokhti et al,³⁵ Yiamsawasd et al,³⁷ and Khedkar et al⁴⁹ and the predictions'

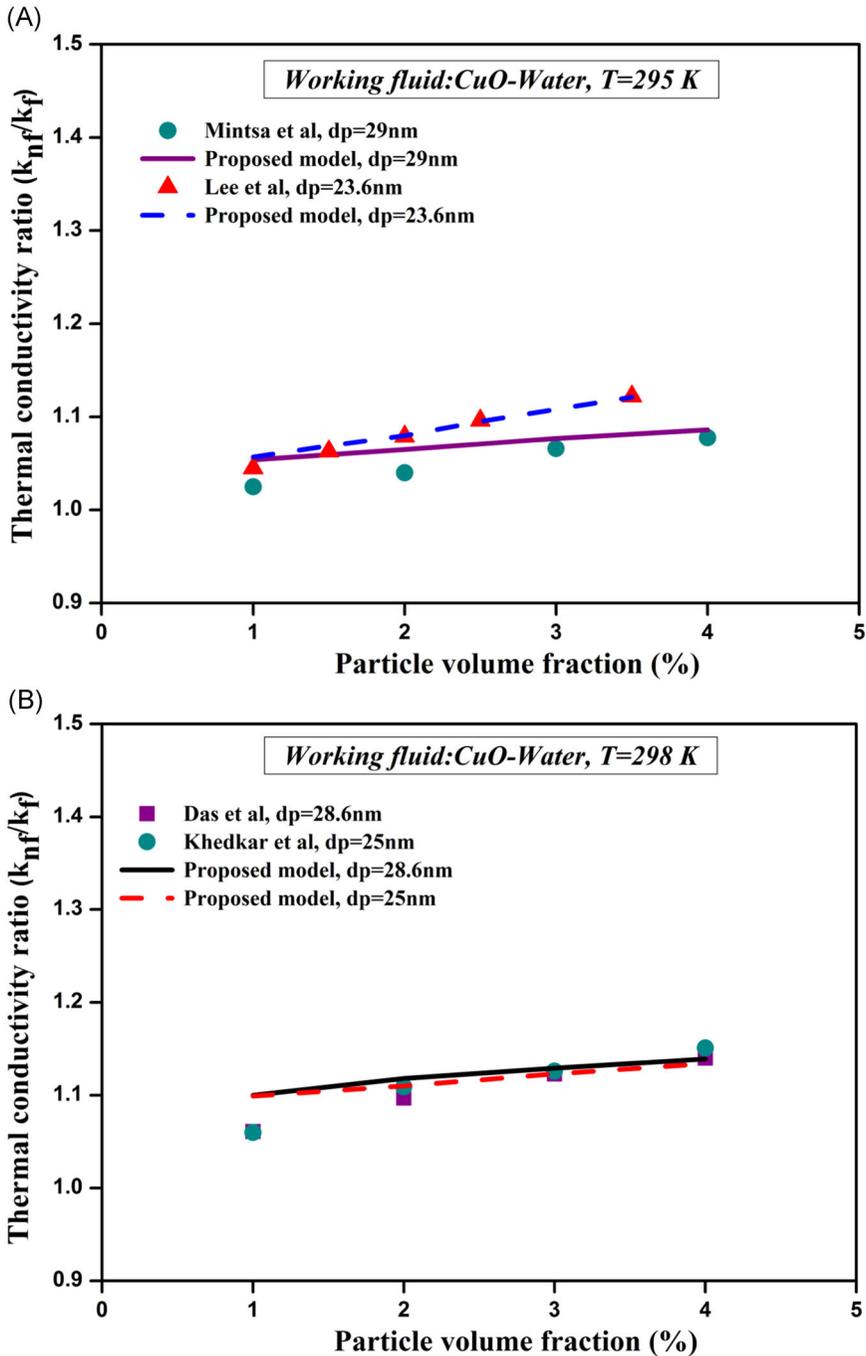


FIGURE 4 Effects of nanoparticles volume fraction on the thermal conductivity ratio of CuO-water nanofluid for different diameters at (A) 295K and (B) 298K, compared with the proposed model [Color figure can be viewed at wileyonlinelibrary.com]

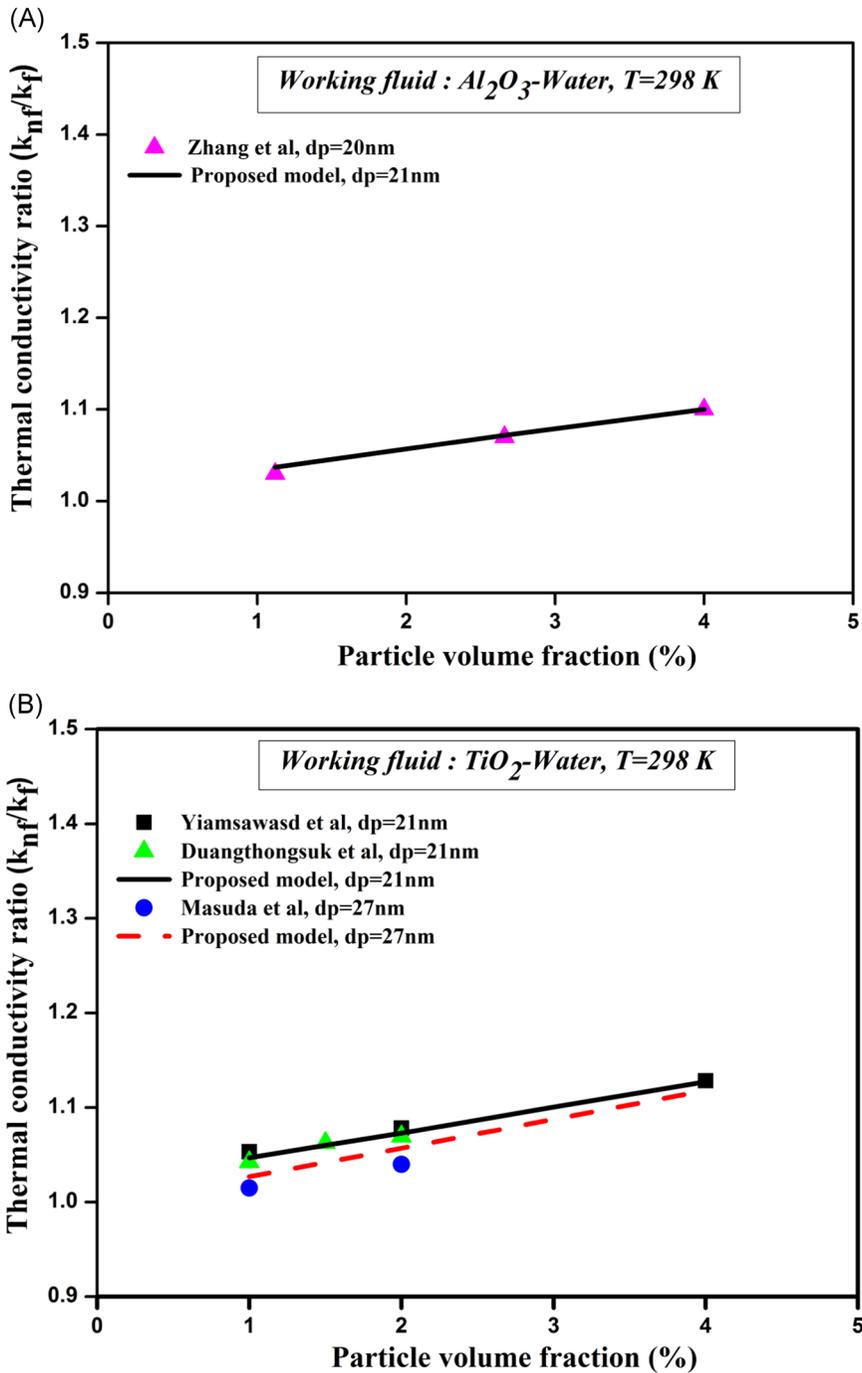


FIGURE 5 Effects of nanoparticles volume fraction on the nanofluids thermal conductivity ratio of (A) Al₂O₃-water and (B) TiO₂-water for different diameters, compared the proposed model [Color figure can be viewed at wileyonlinelibrary.com]

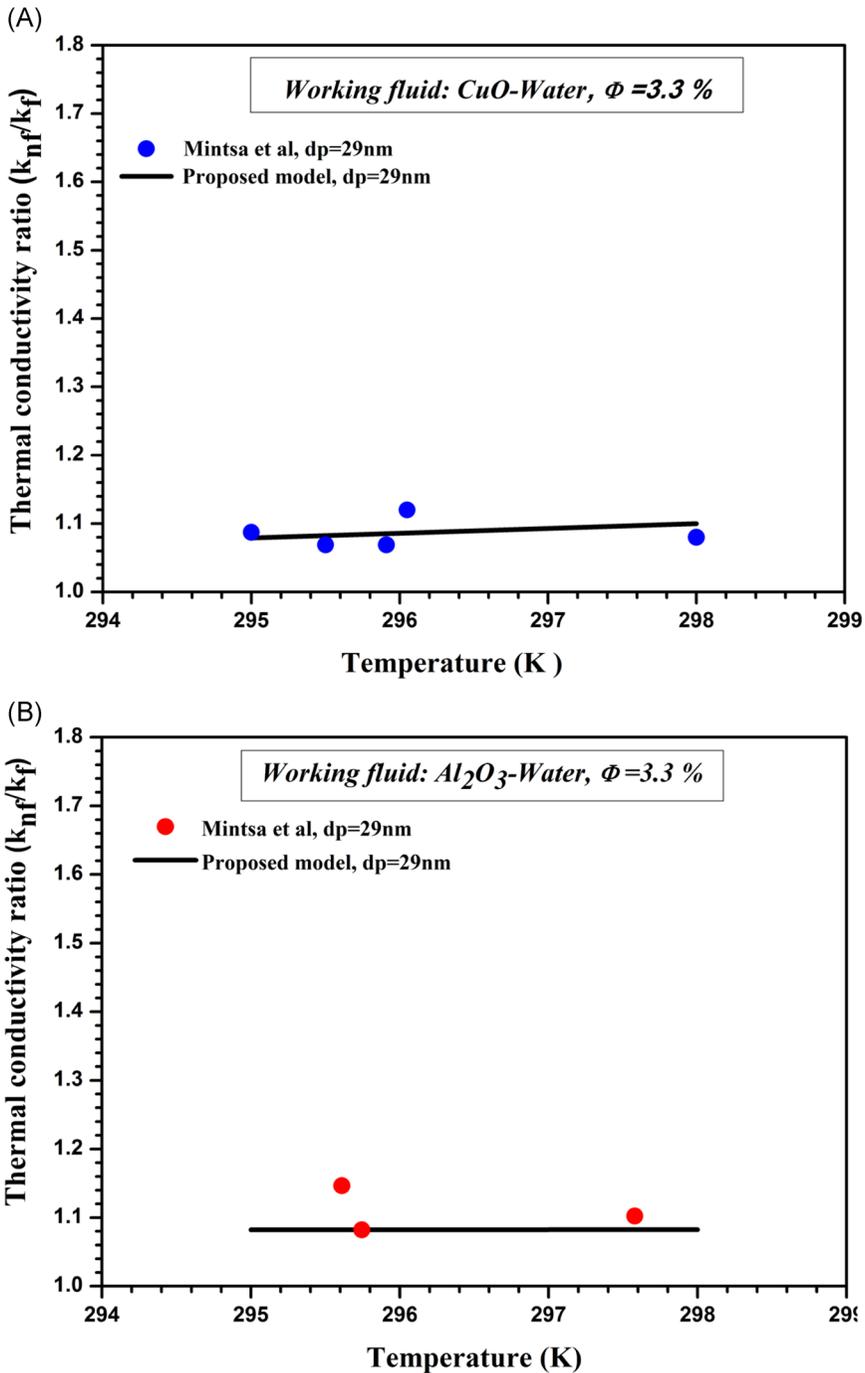


FIGURE 6 Effects of temperatures on the nanofluids thermal conductivity ratio of (A) CuO-water and (B) Al_2O_3 -water compared with the proposed model [Color figure can be viewed at wileyonlinelibrary.com]

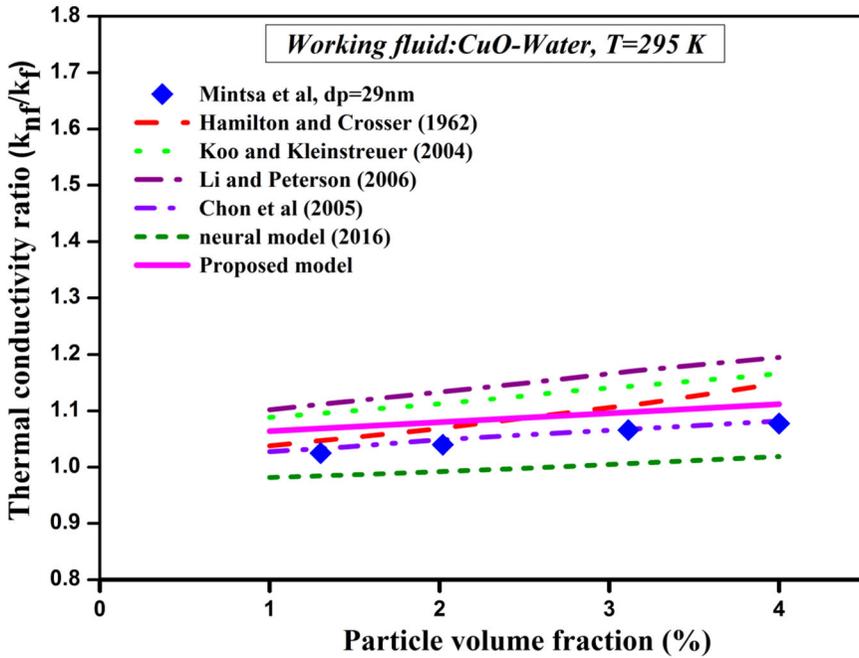


FIGURE 7 Comparison of CuO-water nanofluids thermal conductivity ratio experimental and theoretical models results with the suggested new model, as a function of volume fraction [Color figure can be viewed at wileyonlinelibrary.com]

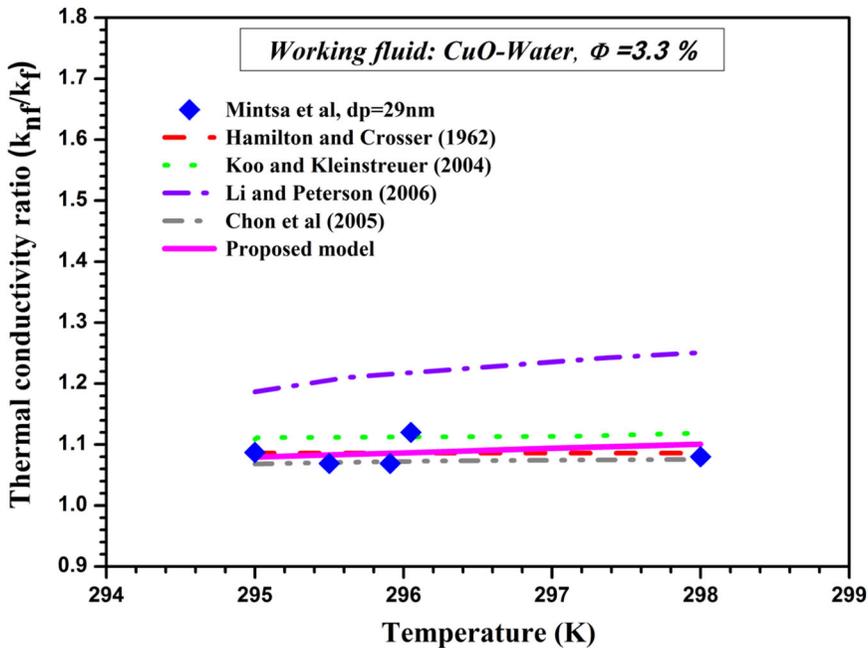


FIGURE 8 Comparison of CuO-water nanofluids thermal conductivity ratio of experimental and theoretical models results with the proposed model, as a function of temperatures [Color figure can be viewed at wileyonlinelibrary.com]

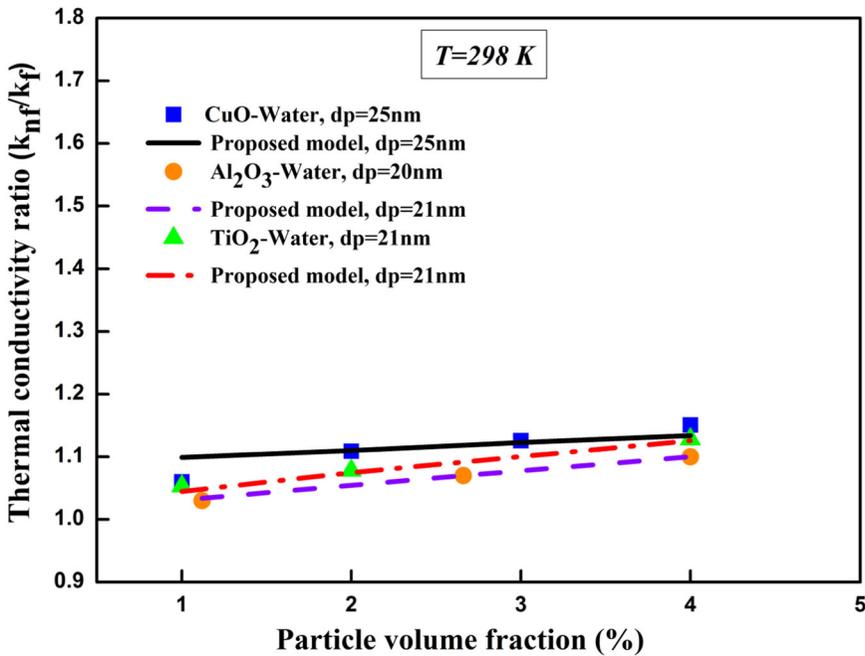


FIGURE 9 Effects of particle volume fraction on the nanofluids thermal conductivity ratio for different nanoparticles compared to the proposed model [Color figure can be viewed at wileyonlinelibrary.com]

results of the present model are within a good accurateness compared with experimental results.

6 | CONCLUSION

In this study, a full factorial design approach was performed to estimate the thermal conductivity enhancement of metallic oxide-water nanofluids of Al₂O₃, TiO₂, and CuO nanoparticles. A new model of TCR of oxide-water nanofluids is developed using expanded and extensive experimental data. This model is applicable to the particle volume fraction range of 1%-4%, at low temperatures of 295K to 298K and particle diameters of 21-29 nm. The factors that affect the thermal conductivity enhancement ratio are identified and analyzed by the ANOVA method. These factors are volume fraction, temperature, nanoparticle average diameter, and nanoparticle type. The results demonstrate that the particle volume fraction has the most significant effect on nanofluids thermal conductivity enhancement compared with other factors. An increase in the particle volume fraction and temperature has a favorable effect on the nanofluids thermal conductivity enhancement, while the higher particle size tends to reduce it. Furthermore, it is found that the nanoparticles volume fraction has a great impact on the thermophysical properties of nanofluids. Thus, the optimum nanoparticle concentration is essential to be determined in forming nanofluids that can enhance thermal systems performance. Finally, the evaluation of the results shows an excellent correlation between predicted and observed TCR responses, indicating good accordance between the suggested model and the experimental data. In addition, the obtained results confirm the effectiveness and capability of the proposed model in predicting nanofluids thermal conductivity with high accuracy.

ACKNOWLEDGMENT

This study was supported by the research laboratory LAIGM of 8 May 1945 Guelma University, Algeria.

ORCID

Wassila Grine  <http://orcid.org/0000-0003-2468-5932>

REFERENCES

1. Choi SUS. Enhancing conductivity of fluids with nanoparticles. *ASME Fluid Eng Division*. 1995;231:99-105.
2. Nair V, Parekh AD, Tailor PR. Water-based Al₂O₃, CuO and TiO₂ nanofluids as secondary fluids for refrigeration systems: a thermal conductivity study. *J Braz Soc Mech Sci & Eng*. 2018;40:1-17.
3. Karimipour A, Bagherzadeh SA, Taghipour A, Abdollahi A, Safaei MR. A novel nonlinear regression model of SVR as a substitute for ANN to predict conductivity of MWCNT-CuO/water hybrid nanofluid based on empirical data. *Physica A*. 2019;521:89-97.
4. Ghasemi A, Hassani M, Goodarzi M, Afrand M, Manafi S. Appraising influence of COOH-MWCNTs on thermal conductivity of antifreeze using curve fitting and neural network. *Physica A*. 2019;514:36-45.
5. Alrashed AA, Gharibdousti MS, Goodarzi M, de Oliveira LR, Safaei MR, Bandarra Filho EP. Effects on thermophysical properties of carbon based nanofluids: experimental data, modelling using regression, ANFIS and ANN. *Int J Heat Mass Transf*. 2018;125:920-932.
6. Amani M, Amani P, Kasaeian A, Mahian O, Wongwises S. Thermal conductivity measurement of spinel-type ferrite MnFe₂O₄ nanofluids in the presence of a uniform magnetic field. *J Mol Liq*. 2017;230:121-128.
7. Amani M, Amani P, Kasaeian A, Mahian O, Pop I, Wongwises S. Modeling and optimization of thermal conductivity and viscosity of MnFe₂O₄ nanofluid under magnetic field using an ANN. *Sci Rep*. 2017;7(1):17369.
8. Ahmadi MH, Nazari MA, Ghasempour R, Madah H, Shafii MB, Ahmadi M. Thermal conductivity ratio prediction of Al₂O₃/water nanofluid by applying connectionist methods. *Colloids Surf A Physicochem Eng Asp*. 2018;541:154-164.
9. Hosseini SM, Safaei MR, Goodarzi M, Alrashed AA, Nguyen TK. New temperature, interfacial shell dependent dimensionless model for thermal conductivity of nanofluids. *Int J Heat Mass Transf*. 2017;114:207-210.
10. Esfahani MA, Toghraie D. Experimental investigation for developing a new model for the thermal conductivity of silica/water-ethylene glycol (40%-60%) nanofluid at different temperatures and solid volume fractions. *J Mol Liq*. 2017;232:105-112.
11. Cabaleiro D, Gracia-Fernández C, Legido JL, Lugo L. Specific heat of metal oxide nanofluids at high concentrations for heat transfer. *Int J Heat Mass Transf*. 2015;88:872-879.
12. Mahian O, Kianifar A, Heris SZ, Wongwises S. Natural convection of silica nanofluids in square and triangular enclosures: theoretical and experimental study. *Int J Heat Mass Transf*. 2016;99:792-804.
13. Goshayeshi HR, Safaei MR, Goodarzi M, Dahari M. Particle size and type effects on heat transfer enhancement of Ferro-nanofluids in a pulsating heat pipe. *Powder Technol*. 2016;301:1218-1226.
14. Khairul MA, Shah K, Doroodchi E, Azizian R, Moghtaderi B. Effects of surfactant on stability and thermophysical properties of metal oxide nanofluids. *Int J Heat Mass Transf*. 2016;98:778-787.
15. Esfe MH, Saedodin S, Bahiraei M, Toghraie D, Mahian O, Wongwises S. Thermal conductivity modeling of MgO/EG nanofluids using experimental data and artificial neural network. *J Therm Anal Calorim*. 2014;118(1):287-294.
16. Sheikholeslami M, Bhatti MM. Forced convection of nanofluid in presence of constant magnetic field considering shape effects of nanoparticles. *Int J Heat Mass Transf*. 2017;111:1039-1049.
17. Qi C, Wang G, Yang L, Wan Y, Rao Z. Two-phase lattice Boltzmann simulation of the effects of base fluid and nanoparticle size on natural convection heat transfer of nanofluid. *Int J Heat Mass Transf*. 2017;105:664-672.

18. Amanuel T, Mishra M. Investigation of thermohydraulic performance of triple concentric-tube heat exchanger with CuO/water nanofluid: Numerical approach. *Heat Trans Asian Res.* 2018;47(8):974-995.
19. Esfe MH, Hajmohammad H, Toghraie D, Rostamian H, Mahian O, Wongwises S. Multi-objective optimization of nanofluid flow in double tube heat exchangers for applications in energy systems. *Energy.* 2017;137:160-171.
20. Mahian O, Kolsi L, Amani M, et al. Recent advances in modeling and simulation of nanofluid flows-Part I: Fundamental and theory. *Phys Rep.* 2019;790:1-48.
21. Goodarzi M, Toghraie D, Reiszadeh M, Afrand M. Experimental evaluation of dynamic viscosity of ZnO-MWCNTs/engine oil hybrid nanolubricant based on changes in temperature and concentration. *J Therm Anal Calorim.* 2019;136(2):513-525.
22. Abdollahi A, Darvanjooghi MHK, Karimipour A, Safaei MR. Experimental study to obtain the viscosity of CuO-loaded nanofluid: effects of nanoparticles' mass fraction, temperature and basefluid's types to develop a correlation. *Meccanica.* 2018;53(15):3739-3757.
23. Bahrani M, Akbari M, Bagherzadeh SA, Karimipour A, Afrand M, Goodarzi M. Develop 24 dissimilar ANNs by suitable architectures & training algorithms via sensitivity analysis to better statistical presentation: Measure MSEs between targets & ANN for Fe-CuO/Eg-Water nanofluid. *Physica A.* 2019;519:159-168.
24. Shen M, Yu D, Hui C. Nonsimilarity boundary layer flow of copper-water nanofluid near stagnation point in a porous medium. *Heat Trans Asian Res.* 2018;47(2):389-403.
25. Yiamsawas T, Dalkilic AS, Mahian O, Wongwises S. Measurement and correlation of the viscosity of water-based Al₂O₃ and TiO₂ nanofluids in high temperatures and comparisons with literature reports. *J Disper Sci Technol.* 2013;34(12):1697-1703.
26. Pramuanjaroenkij A, Tongkratoke A, Kakaç S. Numerical study of mixing thermal conductivity models for nanofluid heat transfer enhancement. *J Eng Phys Thermophys.* 2018;91(1):104-114.
27. Phan NM, Bui HT, Nguyen MH, Phan HK. Carbon-nanotube-based liquids: a new class of nanomaterials and their applications. *Adv Nat Sci: Nanosci Nanotechnol.* 2014;5(1):015014.
28. Rashmi W, Khalid M, Ong SS, Saidur R. Preparation, thermo-physical properties and heat transfer enhancement of nanofluids. *Mater Res Express.* 2014;1(3):032001.
29. Alrashed AA, Karimipour A, Bagherzadeh SA, Safaei MR, Afrand M. Electro-and thermophysical properties of water-based nanofluids containing copper ferrite nanoparticles coated with silica: experimental data, modeling through enhanced ANN and curve fitting. *Int J Heat Mass Transf.* 2018;127:925-935.
30. Shahsavari A, Khanmohammadi S, Karimipour A, Goodarzi M. A novel comprehensive experimental study concerned synthesizes and prepare liquid paraffin-Fe₃O₄ mixture to develop models for both thermal conductivity & viscosity: A new approach of GMDH type of neural network. *Int J Heat Mass Transf.* 2019;131:432-441.
31. Bagherzadeh SA, D'Orazio A, Karimipour A, Goodarzi M, Bach QV. A novel sensitivity analysis model of EANN for F-MWCNTs-Fe₃O₄/EG nanofluid thermal conductivity: outputs predicted analytically instead of numerically to more accuracy and less costs. *Physica A.* 2019;521:406-415.
32. Dasgupta D, Mondal K. Thermal circuits based model for predicting the thermal conductivity of nanofluids. *Int J Heat Mass Transfer.* 2017;113:806-818.
33. Alawi OA, Sidik NAC, Xian HW, Kean TH, Kazi SN. Thermal conductivity and viscosity models of metallic oxides nanofluids. *Int J Heat Mass Transfer.* 2018;116:1314-1325.
34. Aminian A. Predicting the effective thermal conductivity of nanofluids for intensification of heat transfer using artificial neural network. *Powder Technol.* 2016;301:288-309.
35. Kazemi-Beydokhti A, Heris SZ, Moghadam N, Shariati-Niasar M, Hamidi AA. Experimental investigation of parameters affecting nanofluid effective thermal conductivity. *Chem Eng Commun.* 2014;201(5):593-611.
36. Duangthongsuk W, Wongwises S. Heat transfer enhancement and pressure drop characteristics of TiO₂-water nanofluid in a double-tube counter flow heat exchanger. *Int J Heat Mass Transf.* 2009;52:2059-2067.
37. Yiamsawas T, Dalkilic AS, Wongwises S. Measurement of the thermal conductivity of titania and alumina nanofluids. *Thermochim Acta.* 2012;545:48-56.
38. Longo GA, Zilio C, Ortombina L, Zigliotto M. Application of artificial neural network (ANN) for modeling oxide-based nanofluids dynamic viscosity. *Int Commun Heat Mass.* 2017;83:8-14.
39. Salman SD. Comparative study on heat transfer enhancement of nanofluids flow in ribs tube using CFD simulation. *Heat Trans Asian Res.* 2019;48(1):148-163.

40. Nazari S, Akbari E. Numerical investigation of non-Newtonian nanofluid mixed convection in a two-opposite direction lid-driven cavity with variable properties. *Heat Trans Asian Res.* 2018;48(2):1-23.
41. Mebarek-Oudina F. Convective heat transfer of Titania nanofluids of different base fluids in cylindrical annulus with discrete heat source. *Heat Trans Asian Res.* 2018;48(1):1-13.
42. Ben Hamida MB, Charrada K. Natural convection heat transfer in an enclosure filled with an ethylene glycol—copper nanofluid under magnetic fields. *Numer Heat Tr A-Appl.* 2015;67(8):902-920.
43. Marcus Y. *The Properties of Solvents.* New York, NY: John Wiley & Sons; 1998.
44. Bounouri Y, Berkani M, Zamouche A, Rycerz L. Optimization and modeling of synthesis parameters of neodymium (III) bromide by dry method using full factorial design analysis. *Arab J Chem.* 2017.
45. Barka N, Abdennouri M, Boussaoud A, et al. Full factorial experimental design applied to oxalic acid photocatalytic degradation in TiO₂ aqueous suspension. *Arab J Chem.* 2014;7(5):752-757.
46. Barari F, Morgan R, Barnard P. A Design of Experiments (DOE) approach to optimise temperature measurement accuracy in Solid Oxide Fuel Cell (SOFC). *J Phys: Conf Ser.* 2014;547(1):012004.
47. Kumar L, Reddy MS, Managuli RS, Pai G. Full factorial design for optimization, development and validation of HPLC method to determine valsartan in nanoparticles. *Saudi Pharm J.* 2015;23(5):549-555.
48. Zerradi H, Ouaskit S, Dezairi A, Loulijat H, Mizani S. New Nusselt number correlations to predict the thermal conductivity of nanofluids. *Adv Powder Technol.* 2014;25(3):1124-1131.
49. Khedkar RS, Sonawane SS, Wasewar KL. Influence of CuO nanoparticles in enhancing the thermal conductivity of water and monoethylene glycol based nanofluids. *Int Commun Heat Mass.* 2012;39(5):665-669.
50. Chon CH, Kihm KD, Lee SP, Choi SUS. Empirical correlation finding the role of temperature and particle size for nanofluid (Al₂O₃) thermal conductivity enhancement. *Appl Phys Lett.* 2005;87(15):153107.
51. Koo J, Kleinstreuer C. A new thermal conductivity model for nanofluids. *J Nanopart Res.* 2004;6(6):577-588.
52. Li CH, Peterson GP. Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids). *J Appl Phys.* 2006;99(8):084314.
53. Hamilton RL, Crosser OK. Thermal conductivity of heterogeneous two-component systems. *Ind Eng Chem Fundam.* 1962;1(3):187-191.

How to cite this article: Grine W, Benhamza MEH. Modeling the effective thermal conductivity of nanofluids using full factorial design analysis. *Heat Transfer—Asian Res.* 2019;48:2930-2947. <https://doi.org/10.1002/htj.21524>