République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Yahia FARES de MÉDÉA

Faculté de la Technologie



THÈSE EN VUE DE L'OBTENTION D'UN DIPLÔME DE DOCTORAT LMD EN GENIE MECANIQUE

Option : Energétique nucléaire

Thème

Contribution à la modélisation de l'ébullition : Etude comparative

Présentée par : Mr. ADEL BOUALI

Devant le jury composé de :

TRIKI Zakaria	**MCA**	**Université de Médéa**	**Président**
ROUDANE Mohamed	**MCA**	**Université de Blida 1**	**Examinateur**
CHIBA Younes	**MCA**	**Université de Médéa**	**Examinateur**
HANINI Salah	**Prof**	**Université de Médéa**	**Directeur de thèse**
MOHAMMEDI Brahim	**MRA**	**CRNB - Birine**	**Co-Directeur de thèse**

Année universitaire : 2021/2022.

Dédicace

Je dédie ce modeste travail à mes très chers parents pour toute l'affection, tendresse et l'attention dans mes études

À mes frères et mes sœurs

À chère Meriem

À tous les professeurs et les enseignants qui ont pour ma bonne formation depuis mes début jusqu'à la fin de mon cursus universitaire

À tous mes amis

À tous mes chères élèves

(filière :Génie mécanique - Lycée Souidania)

Remerciements

Tout *d'abord, louange à* ***Allah*** *qui m'a guidé sur le droit chemin tout au long du travail et m'a inspiré les bons pas et les justes reflexes. Sans sa miséricorde, ce travail n'aura pas abouti.*

Je *présente mes sincères remerciements avec mes profonds respects à mon Directeur de thèse, Monsieur* ***Salah HANINI****, Professeur à l'Université Yahia Farés de Médéa, qui a assuré la gestion quotidienne de ma recherche. Son immense expérience, ses fructueux conseils et critiques scientifiques ainsi que sa disponibilité régulière qui ont fortement facilité l'avancement de ce travail de recherche.*

J'*exprime aussi mes plus vifs remerciements à mon Co-directeur de thèse, Monsieur* ***Brahim MOHAMMEDI*** *Maître de recherche A, CRNB, d'abord pour m'avoir fait confiance, donné l'honneur de travailler à ces côtés et pour m'avoir accompagné pour mes premiers pas dans le monde de la recherche, pour son soutien moral, ces remarques, ces encouragements et sa disponibilité permanente.*

Je suis sensible à l'honneur que m'a fait le Docteur ***Z. TRIKI*** *Maitre de Conférences A à l'Université Yahia Farès de Médéa en acceptant la présidence du jury de thèse. Je le prie de bien vouloir trouver ici l'expression de ma gratitude.*

Mes remerciements s'adressent aussi au Docteur ***Y. CHIBA*** *Maitre de Conférences A à l'Université Yahia Farès de Médéa et au Docteur* ***M. ROUDANE*** *Maitre de Conférences A à l'université de Blida1, pour avoir bien voulu examiner le contenu de ce travail et participer à la soutenance.*

Je *remercie tous ceux qui ont participé de près ou de loin à l'achèvement de ce travail.*

Résumé : Contribution à la modélisation de l'ébullition

.

L'objectif de travail de recherche présenté dans le cadre de cette thèse de Doctorat est l'utilisation et l'application de certaines techniques de l'intelligence artificielle (les réseaux de neurones artificielles et les vecteurs à support machine) pour modéliser le phénomène de transfert de chaleur par ébullition. La première partie de ce travail vise à développer un modèle neuronale pour la prédiction du coefficient de transfert de chaleur d'un écoulement en ébullition dans un tube incliné et de déterminer l'effet de l'orientation sur le coefficient de transfert de chaleur (HTC). La deuxième contribution consiste à élaborer un modèle permet de calculer le coefficient de transfert de chaleur d'un écoulement en ébullition en film dans un tube verticale. Dans la troisième contribution, nous avons développé un modèle basé sur les réseaux de neurones artificiels pour la prédiction du coefficient de transfert thermique des écoulements en ébullition des nanofluides à base d'eau dans un tube horizontale. La dernière contribution consiste à appliquer la technique des vecteurs à support machine pour développer deux modèles de prédiction du HTC pour des écoulements en ébullition des nanofluides Al_2O_3/eau et TiO_2/eau dans un tube horizontale. La comparaison des résultats des différents modèles développés avec les données expérimentales et avec les corrélations empiriques de la littérature montre un bon accord.

Mots clés : ébullition, nanofluides, RNA, SVM

Abstract: Contribution to modelling of boiling

In this thesis, we applied a some techniques of artificial intelligence (Neural Networks and support vector machine) for modeling flow boiling heat transfer. The first part of this work aims to develop a neural model for the prediction of the heat transfer coefficient of the flow boiling in an inclined tube and to determine the effect of orientation on the heat transfer coefficient (HTC). The second contribution aims to develop a model to calculate the heat transfer coefficient for flow film boiling in a vertical tube. In the third contribution, we have developed a model based on artificial neural networks for the prediction of the heat transfer coefficient for flow boiling of water-based nanofluids in a horizontal tube. The last contribution consists in applying the support vector machine technique to develop two HTC prediction models for flow boiling of Al_2O_3/water and TiO_2/water nanofluids in a horizontal tube. The comparison of the results of the various developed models with the experimental data and with the empirical correlations of the literature shows a good agreement.

Key words :boiling, nanofluids, ANN, SVM

ملخص: اسهامات في نمذجة الغليان

الهدف من هذا العمل هو استعمال وتطبيق بعض تقنيات الذكاء الاصطناعي (الشبكات العصبونية الاصطناعية، والداعمات ذات التوجيه الالي) من اجل نمذجة ظاهرة التحويل الحراري بالغليان المتدفق.
الجزء الأول من هذا العمل يهدف الى تطوير نموذج يعتمد على الشبكات العصبونية الاصطناعية يسمح بالتنبؤ بمعامل التحويل الحراري أثناء الغليان المتدفق في أنبوب مائل ومعرفة تأثير الميلان على معامل التحويل الحراري, أما الجزء الثاني فيهدف الى انشاء نموذج اخر لحساب معامل التحويل الحراري أثناء الغليان المنفصل المتدفق في أنبوب شاقولي, وفي الجزء الثالث و بالاعتماد دائما على الشبكات العصبونية قمنا بتطوير نموذج يهدف الى التنبؤ بمعامل التحويل الحراري أثناء الغليان المتدفق للسوائل النانوية ذات القاعدة المائية في أنبوب أفقي, وفي الجزء الأخير قمنا بتطبيق تقنية الداعمات ذات التوجيه الالي من أجل تطوير نموذجين يسمحان بحساب معامل التحويل الحراري أثناء الغليان المتدفق للسوائل النانوية (الماء/TiO_2 و الماء/Al_2O_3) في أنبوب أفقي.
قمنا بمقارنة نتائج النماذج المطورة في هذا العمل مع النتائج التجريبية ومع الارتباطات الموجودة في المجتمع العلمي, هذه المقارنة أظهرت أن النماذج المطورة متوافقة بشكل أفضل مع النتائج التجريبية .

كلمات مفتاحية: الغليان, السوائل النانوية, الشبكات العصبونية, الداعمات ذات التوجيه الالي

Table des matières

Table des matières

Table des matières *i*
Liste des figures *v*
Liste des tableaux *xx*
Nomenclature *xxii*
Nomenclature *xxiii*

INTRODUCTION GENERALE 01

Chapitre I : Généralité sur le phénomène d'ébullition

I.1. Introduction 04
I.2. La nucléation 04
I.2.1. La nucléation homogène 04
I.2.2. La nucléation hétérogène 04
I.3. Ebullition en vase clos 06
I.4. Ebullition en convection forcée 06
I.4.1. Configuration d'écoulement 06
I.4.1.1. Configuration d'écoulement horizontale 06
I.4.1.2. Configuration d'écoulement verticale 08
I.5. La crise d'ébullition 10
I.6. Ebullition des nanofluides 11
I.6.1. Notion sur les nanofluides 11
I.6.2. Préparation des nanofluides 12
I.6.3. Caractéristiques thermo physiques des nanofluides 15
I.7. Effets paramétriques sur l'ébullition 16
I.7.1. Pression du système 16
I.7.2. La gravité 16
I.7.3. Gaz dissous 16
I.7.4. La rugosité 16
I.7.5. La sous saturation 17
I.8. Grandeurs caractéristiques d'un écoulement diphasique 17
I.8.1. La température de saturation 17

I.8.2. La pression de saturation 17
I.8.3. La surchauffe 17
I.8.4. Le sous refroidissement 18
I.8.5. Le taux de vide 18
I.8.6. Le titre massique 18
I.8.7. Le titre thermodynamique 18
I.8.8. Le titre volumique 19
I.8.9. Le débit spécifique 19
I.9. L'ébullition dans les réacteurs nucléaires 19
I.9.1. Les réacteurs à eau sous pression (REP) 19
I.9.2. Les réacteurs à eau bouillante (REB) 20
I.9.3. Les réacteurs nucléaires et les nanofluides 21
I.9.4. Sûreté des réacteurs nucléaires 22
I.10. Conclusion 24

Chapitre II : Revue bibliographique

II.1. Introduction 25
II.2. Revues sur l'ébullition des fluides 25
II.2.1. Modélisation de l'ébullition des fluides par RNA 34
II.2.2. Modélisation de l'ébullition des fluides par SVM 35
II.3. Revues sur l'ébullition des nanofluides 36
II.3.1. Modélisation de l'ébullition des nanofluides par RNA 41
II.3.2. Modélisation de l'ébullition des nanofluides par SVM 42
III.4. Conclusion 43

Chapitre III : Techniques d'intelligence artificielles

III.1. Introduction 44
III.2. Les réseaux de neurones artificiels 45
III.2.1. Le neurone 45
III.2.2. Base biologique 45
III.2.3. Le neurone artificielle 46
III.2.4. Architecture des réseaux de neurones 49
III.2.5. Connexions des réseaux de neurones 49
III.2.6. Réseaux de neurones multicouches 50
III.2.7. Apprentissage des réseaux de neurones 51
III.2.8. Algorithmes d'apprentissage 51
III.2.9. Rétropropagation du gradient 52
III.3. Machine à vecteurs support 56
III.3.1. Apprentissage des machines à vecteurs support 56

III.4. Conclusion 57

Chapitre IV : Modélisation de l'ébullition par les techniques d'intelligence artificielles

IV.1. Introduction 59
IV.2. Modélisation de l'ébullition dans un tube incliné 60
IV.2.1. Introduction 60
IV.2.2. Matériel et méthode 60
IV.2.3. Résultats et discussions 62
IV.2.3.1. Validation du modèle RNA 68
IV.2.3.2. Détermination de l'importance de chaque variable d'entrée 69
IV.2.3.3. Programme informatique pour calculer HTC 70
IV.2.4. Conclusion 70
IV.3. Modélisation de l'ébullition en film 72
IV.3.1. Introduction 72
IV.3.2. Approche neuronale 92
IV.3.3. Critères de performance statistique 75
IV.3.4. Résultats et discussions 76
IV.3.4.1. Programme de calcule du coefficient de transfert de chaleur en ébullition 81
IV.3.5. Conclusion 81
IV.4. Modélisation de l'ébullition des nanofluides par RNA 82
IV.4.1. Introduction 82
IV.4.2. Description du modèle RNA 82
IV.4.3. Critères de performance 85
IV.4.4. Résultats et discussions 86
IV.4.4.1. Effet de la conductivité thermique et de la concentration sur HTC 88
IV.4.4.2. Effet de débit massique et flux de chaleur sur HTC 88
IV.4.4.3. Performance du nanofluide 89
IV.4.4.4. Validation du modèle intelligent 90
IV.4.4.5. Analyse de sensibilité 91
IV.4.5. Conclusion 92
IV.5. Modélisation de l'ébullition des nanofluides par SVM 94
IV.5.1. Introduction 94
IV.5.2. Description du modèle SVR 94
IV.5.3. Evaluation du modèle SVR 97
IV.5.4. Résultats et discussions 97
IV.5.5. Conclusion 101

CONCLUSION GENERALE ET PERSPECTIVES 102

REFERENCES BIBLIOGRAPHIQUE

Liste des figures

Chapitre I : Généralité sur le phénomène d'ébullition

Figure I-1	Courbe d'ébullition ou courbe de Nukiyama	05
Figure I-2	Configurations de l'écoulement horizontal	08
Figure I-3	Evolution des configurations d'écoulement, des températures et des régimes thermiques dans un tube vertical chauffant	10
Figure I-4	Différents mécanismes de crise d'ébullition à faible titre ''caléfaction''	11
Figure I-5	Pyrolyse laser donnant de la nanopoudre à mélanger au liquide et dépôt direct dans le liquide par pulvérisation cathodique sous vide.	13
Figure I-6	Nanoparticule (Ag)	14
Figure I-7	Nanoparticule (TiO_2)	14
Figure I-8	Nanoparticules sphériques; Nanotubes de carbone	14
Figure I-9	Effet de la pression du système sur l'ébullition nucléée	16
Figure I-10	Effet de l'état de surface de l'élément chauffant	17
Figure I-11	Schéma de principe d'un PWR	20
Figure I-12	Schéma de principe d'un PWR.	21
Figure I-13	Conditions d'opération d'un PWR et d'un BWR	22
Figure I-14	Endommagement par "isolation" de la paroi chaude du liquide de refroidissement	23

Chapitre II : Revue bibliographique

Figure II-1	Comparaison d'un tube amélioré et lisse en relation avec un faisceau de tubes	26
Figure II-2	Rayon équivalent de la bulle pour différentes températures de surface	26
Figure II-3	Glissement d'une bulle sur un tube horizontal	27
Figure II-4	Comparaison de données sur un tube tisse avec R114	28
Figure II-5	Evolution des articles publiées pour la prédiction du coefficient de transfert de chaleur pour des écoulemnets en ébullition des fluides par RNA	35
Figure II-6	Evolution des articles publiées pour la prédiction du coefficient de transfert de	36

	chaleur pour des écoulemnets en ébullition des fluides par SVM	
Figure II-7	Evolution des articles publiées pour la prédiction du coefficient de transfert de chaleur pour des écoulemnets en ébullition des nanofluides par RNA	42
Figure II-8	Evolution des articles publiées pour la prédiction du coefficient de transfert de chaleur pour des écoulemnets en ébullition des nanofluides par SVM	43

Chapitre III : Techniques d'intelligence artificielles

Figure III -1	Les techniques d'intelligence artificielles utilisées pour la modélisation du transfert de chaleur en ébullition	44
Figure III -2	Neurone biologique avec son arborisation dendritique	46
Figure III -3	Modèle générale d'un neurone	47
Figure III -4	Fonctions de sortie des neurones	48
Figure III -5	Connexions directes	49
Figure III -6	Connexions récurrentes	49
Figure III -7	Connexions partielles	50
Figure III -8	Connexions totales.	50
Figure III -9	Réseaux de neurones multicouches	50
Figure III -10	Flux des signaux de la rétropropagation	52
Figure III -11	Algorithme de la rétropropagation de l'erreur.	55

Chapitre IV : Modélisation de l'ébullition par les techniques d'intelligence articielles

Figure IV -1	Graphiques de régression de l'ANN pour la prédiction du coefficient de transfert de chaleur (Tous les ensembles de données)	65
Figure IV -2	Tracé des résidus pour les valeurs calculées de HTC à partir de l'ANN modèle par rapport à leurs valeurs expérimentales pour les ensembles d'apprentissage, de test et de validation	65
Figure IV -3	Diagramme de probabilité normale du modèle ANN pour prédire HTC	66
Figure IV -4	L'effet d'orientation sur le HTC	67
Figure IV -5	L'effet de qualité sur le HTC	67
Figure IV -6	L'effet de débit massique sur le HTC	67
Figure IV -7	Comparaisons de la prédiction ANN de HTC avec des données expérimentales et des corrélations empiriques dans le canal verticale	68

Figure IV -8	Comparaisons de la prédiction de l'ANN de l'effet d'orientation sur HTC avec les résultats expérimentales	68
Figure IV -9	Importance relative des variables d'entrée sur la sortie	69
Figure IV -10	Interface Matlab pour le calcul de HTC	70
Figure IV -11	L'effet du nombre de neurone dans les couches cachées sur RMSE	73
Figure IV -12	Structure optimale du modèle RNA	74
Figure IV -13	Graphe de régression du RNA modèle (apprentissage)	76
Figure IV -14	Graphe de régression du RNA modèle (validation)	77
Figure IV -15	Graphe de régression du RNA modèle (test)	77
Figure IV -16	Distribution de l'erreur absolue AE%	78
Figure IV -17	L'effet de la pression sur HTC	78
Figure IV -18	L'effet de flux de chaleur sur HTC	79
Figure IV -19	L'effet de débit massique et de qualité sur HTC	79
Figure IV -20	L'importance des variables d'entrée sur HTC	80
Figure IV -21	Interface Matlab pour le calcul du coefficient de transfert thermique	81
Figure IV -22	La plateforme d'architecture de l'ANN optimal	84
Figure IV -23	Diagramme de régression ANN	86
Figure IV -24	Les résidus versus leurs valeurs expérimentales	87
Figure IV -25	L'effet de la concentration volumétrique et l'effet de la conductivité thermique sur HTC	88
Figure IV -26	L'effet de débit massique et flux de chaleur sur HTC	89
Figure IV -27	L'effet de débit massique et flux de chaleur sur HTC	89
Figure IV -28	Comparaison du modèle ANN avec les corrélations empiriques et avec les données expérimentales	91
Figure IV -29	Effet des variables d'entrée sur HTC	92
Figure IV -30	Organigramme du processus d'optimisation des modèles SVR	96
Figure IV -31	Graphe de régression du SVR modèle pour TiO_2 / eau nanofluide	98
Figure IV -32	Graphe de régression du SVR modèle pour Al_2O_3/ eau nanofluide AG).	98

Figure IV -33 Comparaison entre les prédictions SVR-RBF modèle pour TiO_2/ eau nanofluide et les données expérimentales 99

Figure IV -34 Comparaison entre les prédictions SVR-RBF modèle pour Al_2O_3/ eau nanofluide et les données expérimentales 99

Figure IV -35 Comparaison entre les prédictions SVR-RBF modèle pour Al_2O_3/ eau nanofluide et la corrélation empirique de Gong et al 100

Figure IV -36 Comparaison entre les prédictions SVR-RBF modèle pour TiO_2/ eau nanofluide et la corrélation empirique de Gong et al 100

Liste des tableaux

Chapitre II : Revue bibliographique

Tableau II -1	Valeurs de C_{sf} dans la corrélation de Rohsenow	29
Tableau II- 2	Méthodes de prédiction du transfert thermique des écoulements en ébullition	34
Tableau II -3	Résumé des investigations expérimentales sur le HTC pour l'ébullition en vase des nanofluides.	40
Tableau II -4	Résumé des investigations expérimentales sur le HTC des écoulements en ébullition des nanofluides	41

Chapitre III : Techniques d'intelligence artificielles

Tableau III.1	Transition entre le neurone biologique et le neurone formel	47

Chapitre IV : Modélisation de l'ébullition par les techniques d'intelligence artificielles

Tableau IV-1	Gamme de variables	61
Tableau IV-2	Architecture du modèle ANN optimisé	62
Tableau IV-3	Performance statistique de l'ANN	63
Tableau IV-4	Les valeurs optimales des poids et biais obtenus lors de l'apprentissage de l'ANN	64
Tableau IV-5	Gamme de variables	72
Tableau IV-6	L'effet d'algorithme d'apprentissage sur la performance du RNA	74
Tableau IV-7	Performances statistiques du modèle RNA	76
Tableau IV-8	Gamme de variables	83
Tableau IV-9	La conductivité thermique des nanoparticules utilisées	83
Tableau IV-10	Critères de performances du modèle RNA	86
Tableau IV-11	Les valeurs optimales des poids et des biais du modèle ANN	87
Tableau IV-12	Comparaison avec d'autres ANN modèles	90
Tableau IV-13	Gamme variables pour Al_2O_3/H_2O nanofluide	96

Tableau IV-14	Gamme variables pour TiO_2/H_2O nanofluide	96
Tableau IV-15	SVR-Model avec différents fonctions de noyau pour TiO_2/water nanofluide	97
Tableau IV-16	SVR-Modèle avec différents fonctions de noyau pour Al_2O_3/water nanofluide	97

Nomenclature

Acronyme	Signification	Unités
$\mathbf{A_f}$	Facteur de précision	
ANN	Artificial neural network	
ANNs	Artificial neural network structure	
$\mathbf{B_f}$	Facteur de biais	
$\mathbf{b_j}$	Valeurs de biais de la couche cachée	
$\mathbf{b_{out}}$	Valeurs de biais de la couche de sortie	
C	Concentration volumique des nanoparticules	%
CHF	Critical heat flux	($W.m^{-2}$)
G	Flux massique	($Kg.m^{-2}.S^{-1}$)
HTC	Coefficient de transfert de chaleur	($W/m^2.K$)
$\mathbf{I_j}$	Importance relative	%
$\mathbf{imp_t}$	Importances relatives des variables d'entrées	%
K, K'	Critères d'acceptabilité	
LMI	l'indice de Legates-McCabe	
MLP	Perceptron multicouche	
MRAE	L'erreur relative absolue moyenne	
MSE	L'erreur quadratique moyenne	$(W/m^2.K)^2$
$\mathbf{N_h}$	Nombre de neurones de la couche cachée	
$\mathbf{N_p}$	Nombre de neurones de la couche d'entrée	
P	La Pression	(kPa)
q	Flux de chaleur	($MW.m^{-2}$)
R	Coefficient de corrélation	
$\mathbf{R^2}$	Coefficient de détermination	
RMSE	Racine de l'erreur quadratique moyenne	($W/m^2.K$)
RNA	Réseaux de neurones artificiels	
RAE	Erreur relative absolue	%

RI	Relative importance	%
RBF	Radial basis fonction	
STDEV	Ecart type	
SVM	Machine à vecteur de support	
SVR	Support vector regression	
$\mathbf{V_j}$	Vecteur des poids synaptiques entre la couche cachée et la couche d'entrée	
$\mathbf{W_{ij}}$	Vecteur des poids synaptiques entre la première couche cachée et la deuxième couche de sortie	
$\mathbf{W_{ih}}$	Vecteur des poids synaptiques entre la couche cachée et la couche d'entrée	
$\mathbf{W_{ho}}$	Vecteur des poids synaptiques entre la couche cachée et la couche de sortie	
WI	L'indice de concordance	
Xe	Titre thermodynamique	%

Exposants et indices

EXP	Valeur expérimentale
h	Couche cachée
i	Couche d'entrée
max	Maximum
min	Minimum
o	Couche de sortie
Pred	Les valeurs prédites

Lettres grecques

ω	Facteur de poids	
ξ_i, ξ_i^*	Variable de relachement	
λ	Conductivité thermique du nanopaticule	$W.m^{-1}.K^{-1}$
θ	L'angle d'inclinaison	Dégrée (°)

Introduction générale

L’ébullition est le processus de transfert thermique d’une paroi chauffée vers un liquide, associé à un changement de phase se traduisant par la formation de bulles de vapeur dans le liquide. L’ébullition libre (ou ébullition en vase, qui se rapproche davantage de son équivalent anglais « pool boiling » fait référence à l’ébullition dans un liquide immobile en l’absence de sollicitation thermique et se distingue de l’ébullition convective pour laquelle le fluide est mis en mouvement par un organe externe comme une pompe. Le phénomène d’ébullition occupe une grande place dans de nombreux domaines industriels car il permet de dissiper des densités de flux élevées avec des écarts de température entre la paroi et le fluide relativement faibles. Il est ainsi mis en œuvre dans des opérations de refroidissement de systèmes dissipatifs (composants électroniques, moteurs, etc.), dans des échangeurs thermiques (évaporateurs de systèmes frigorifiques, de systèmes de conversion d’énergie thermo-mécanique, etc.), ou encore dans les centrales nucléaires.

Les écoulements diphasiques liquide/vapeur en tubes, canaux ou dans différentes géométries sont fréquemment rencontrés dans l’industrie nucléaire. En effet, les fortes puissances générées dans le cœur d’un réacteur nucléaire nécessitent l’évacuation de celles-ci par le biais d’une circulation continue du fluide réfrigérant à travers les éléments combustibles. Il s’agit d’extraire des densités de flux de chaleur très élevées à partir des surfaces d’échanges réduites ; l'ébullition peut considérablement améliorer le transfert de chaleur. Néanmoins, dans certaines conditions appelées "conditions critiques" la vapeur produite forme une barrière thermique entraînant une montée brusque de la température, le flux thermique critique provoque une dégradation brutale du coefficient de transfert de chaleur pouvant entraîner la fusion de la paroi chauffante. Ce phénomène est appelé "crise d'ébullition", la crise d'ébullition est un phénomène brutal et destructif qu'il faut à tout prix éviter son apparition dans les systèmes thermiques.

L’ébullition reste un phénomène physique difficile à cerner et à modéliser, puisqu’il dépend de plusieurs paramètres comme la pression de saturation, la température de saturation, les propriétés thermo-physiques du fluide, les caractéristiques de surface, les propriétés thermo-physiques du matériau, dimensions, orientation, épaisseur, état de surface...

Pour la prédiction du coefficient de transfert de chaleur (HTC) d'un écoulement saturée en ébullition dans un tube incliné, la prédiction du coefficient de transfert de chaleur pour un écoulement en ébullition en film, la prédiction du coefficient de transfert de chaleur d'un écoulement saturé des nanofluides dans un tube horizontale. De nombreux travaux de recherche ont été menés à ce sujet, mais en raison de la complexité de l'ébullition, il est assez difficile d'établir un modèle général capable de couvrir un large éventail de conditions. La révolution de l'informatique et le développement de nouvelles méthodes de calcul numérique basé sur l'intelligence artificielle et les sciences cognitives ont donné naissance durant les dernières décennies à de nouvelles méthodes de calcul et de modélisation telles que les réseaux de neurones artificiels (RNA), la machine à vecteurs de support (SVM). L'efficacité, la fiabilité et la robustesse de ces méthodes ont été démontrées par leurs nombreuses applications dans le domaine d'ingénierie.

Le principal avantage de modélisation par l'intelligence computationnelle, comparé aux modèles classiques, est leur capacité à modéliser ces procédés sans avoir une connaissance approfondie des mécanismes mis en jeu. Donc l'investigation de modélisation par l'intelligence computationnelle pour la prédiction du coefficient de transfert de chaleur (HTC) des écoulements en ébullition.

Le premier objectif de ce travail est l'utilisation du réseaux neurones artificielles pour l'élaboration d'un modèle de prédiction du coefficient de transfert de chaleur (HTC) pour un écoulement en ébullition saturé dans un tube incliné, et de déterminer l'effet de l'inclinaison sur le coefficient de transfert de chaleur. Le deuxième objectif de ce travail est l'élaboration d'un autre modèle de prédiction du coefficient de transfert de chaleur d'un écoulement en ébullition saturé des nanofluides dans un tube horizontale.

Pour atteindre l'objectif assigné à cette thèse, quatre chapitres ont été développés. La présente introduction générale a permis de situer le contexte et les motivations de cette recherche.

Le **premier chapitre** est consacré à une généralité sur le phénomène d'ébullition, les différents régimes d'ébullition et les transitions entre ces régimes, la crise d'ébullition, l'ébullition des nanofluides, et les effets paramétriques sur l'ébullition.

Dans le **deuxième chapitre**, nous parlons brièvement sur les techniques de l'intelligence artificielle et spécialement les réseaux de neurones artificielles, et la machine à des vecteurs de support.

Le **troisième chapitre** est consacré à une recherche bibliographique sur la prédiction du coefficient de transfert de chaleur d'un écoulement en ébullition dans un tube verticale, et dans un canal incliné, et une étude bibliographique sur les écoulements des nanofluides dans un tube horizontale.

Le **chapitre quatre** est consacré à la modélisation de l'écoulement en ébullition dans un tube incline, la modélisation de l'ébullition en film, et la modélisation de l'ébullition des nanofluides dans un tube horizontale par l'application de la technique des réseaux de neurones artificielle. Le chapitre quatre est consacré aussi à la modélisation de l'ébullition des nanofluides par la technique de machine à vecteurs de support.

Les **conclusions** tirées de ce travail ainsi que les études qui peuvent être envisagées dans le futur sont présentés à la fin de cette thèse.

Chapitre I

Généralités sur le phénomène

CHAPITRE I : Généralité sur le phénomene d'ébullition

I.1. Introduction

L'ébullition est un procédé efficace de transfert de chaleur entre une paroi chauffante et un fluide. L'ébullition se produit en convection forcée dans les réacteurs à eau sous pression (REP) en situation accidentelle et dans le cœur des réacteurs nucléaires à eau bouillante (REB).

Ce chapitre vise à faire un point sur l'état de nos connaissances en ce qui concerne le procédé de l'ébullition en convection forcée dans un canal chauffant. En premier lieu, une description phénoménologique de la nucléation, une description générale de l'ébullition en vase et en convection forcée est ainsi consacrée à des notions sur les nanofluides, l'ébullition des nanofluides. Ensuite, nous présentons les principaux types des réacteurs nucléaires et les effets paramétriques sur l'ébullition.

I.2. La nucléation

L'ébullition est, par définition, la formation de bulles de vapeur du fait d'un changement d'état d'un fluide liquide vers son état gazeux. Ce phénomène est plus complexe puisqu'il implique la création des interfaces liquide-vapeur : l'étude de l'ébullition concerne autant la thermodynamique que la mécanique des fluides. La nucléation, c'est à-dire la création d'une bulle de vapeur, par échauffement d'un liquide peut survenir de deux manières. La nucléation au sein d'un liquide métastable est dite homogène, alors que la nucléation hétérogène fait référence à la formation de bulles sur une paroi solide surchauffée.

I.2.1. La nucléation homogène

On appelle nucléation homogène l'apparition de bulles de vapeur au sein d'un liquide pur, suite à l'abaissement brutal de la pression ou à une augmentation de la température au-dessus de la température de saturation.

Le phénomène de nucléation spontanée au sein d'un liquide exempt de tout germe (particules solides, microbulles de gaz non soluble) est complexe. La probabilité que la nucléation homogène se produise dépend de la cinétique de formation de l'embryon de vapeur.

I.2.2. La nucléation hétérogène

En pratique, l'ébullition a lieu à la surface de parois chauffantes : la nucléation est alors dite hétérogène et la formation des bulles dans cette situation nécessite une énergie beaucoup plus faible que dans le cas de la nucléation homogène.

Plusieurs éléments peuvent être la cause de la naissance de bulles dans ces conditions, à savoir la présence de gaz incondensables dissous, des particules en suspension, ou des imperfections sur la paroi solide.

I.3. Ebullition en vase clos

Avant de passer à l'ébullition en convection forcée, il est bon de rappeler les différents régimes d'ébullition rencontrés lors de l'ébullition en vase. L'ébullition en vase c'est l'ébullition que l'on rencontre dans un récipient rempli de fluide à l'état de repos, dans lequel est plongé un élément chauffant fournissant un flux de chaleur sur sa paroi.

L'expérience de Nukiyama [1] consiste à chauffer progressivement un fil plongé dans de l'eau par l'effet de joule et à tracer la courbe donnant la densité de flux de chaleur en fonction de la surchauffe $\Delta T_{SAT} = T_p - T_{SAT}$.

La courbe d'ébullition ou courbe de Nukiyama est représentée dans la figure I.1.

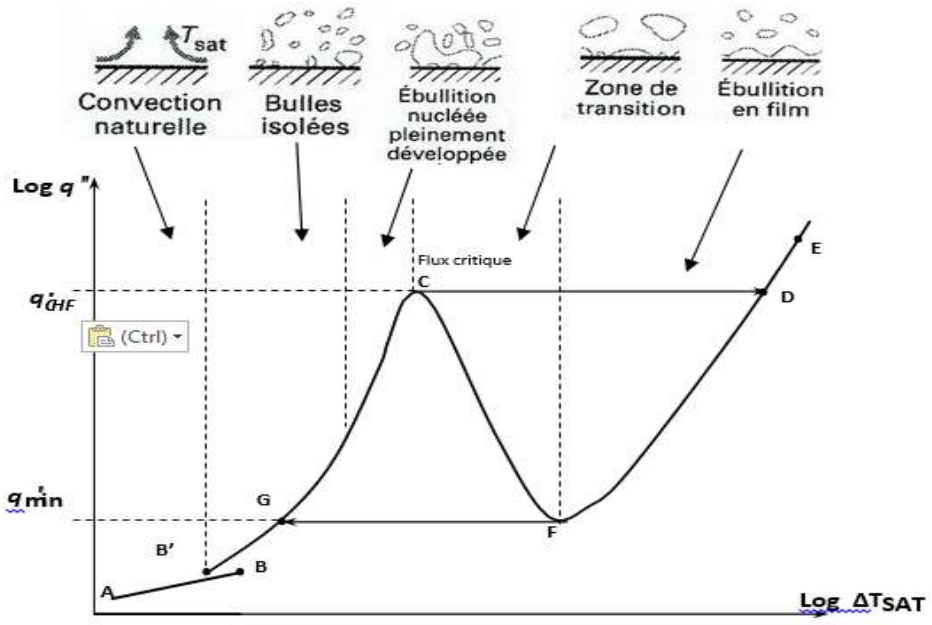


Figure I.1. Courbe d'ébullition ou courbe de Nukiyama [1]

La courbe de Nukiyama montre que l'ébullition nucléée il permet d'évacuer une quantité de chaleur importante avec une faible augmentation de la température de surface, et montre aussi que l'ébullition nucléée est le meilleur régime d'échange.

AB : le régime d'échange est la convection naturelle et le flux de chaleur est insuffisant pour obtenir la surchauffe nécessaire à la formation de bulles.

B' : le point de démarrage de l'ébullition nucléée et la surchauffe de la paroi devient suffisante pour provoquer la formation des bulles de vapeur.

B'G : c'est l'ébullition nucléée à bulles isolées ou ébullition nucléée partielle.

GC : c'est l'ébullition nucléée à poches ou colonnes de vapeur ou encore l'ébullition nucléée complètement développée.

C : ce point correspond au flux crique. Le volume de vapeur produit est tel qu'il se forme une couche isolante de vapeur entre la surface et le fluide. Le coefficient d'échange se dégrade brutalement. Deux cas peuvent se produire : le chauffage est à flux imposé ou à température imposée. Dans la première situation, si on essaie d'augmenter la valeur du flux de chaleur au-delà de cette limite, la température de la surface va croître brutalement. Sur la courbe d'ébullition, on saute directement au point D i.e. à l'ébullition en film. En pratique, le saut de température est si important que la destruction de l'élément chauffant se produit (en anglais 'burnout'). Dans le second cas, la forte résistance thermique de la vapeur oblige l'élément chauffant à prendre cette température. Suivant sa valeur, la destruction de l'appareil surviendra ou non.

CF : l'ébullition de transition dont l'existence dépend fortement de ce qui s'est passé avant est un régime mal défini. C'est la zone instable où du liquide et de la vapeur atteignent tour à tour par intervalles de temps irréguliers la surface chauffée. Sa mise en évidence et son étude nécessite l'utilisation d'un fil chauffant à température imposée.

FE : dans la région d'ébullition en film, un film stable de vapeur couvre la totalité de la surface. Des bulles de vapeur régulièrement espacées à la fois dans l'espace et dans le temps évacuent la chaleur. Le transfert de la chaleur se fait par conduction et par convection à travers ce film de vapeur, le rayonnement devenant significatif au fur et à mesure que la température de la surface augmente et se maintiendra tant que la température de fusion ne sera pas atteinte.

I.4. Ebullition en convection forcée

I.4.1. Configuration d'écoulement

La configuration d'écoulement est l'ensemble des paramètres qui décrivent la forme de chacune des phases dans l'écoulement. Sans savoir le régime d'écoulement, on ne peut pas calculer correctement les paramètres de conception pour des conditions d'écoulement définies telles que le transfert thermique et la chute de pression. Le régime d'écoulement dépend des propriétés du fluide et la géométrie du tube.

I.4.1.1. Configuration d'écoulement horizontale

Les forces physiques principales commandant la distribution des phases dans les écoulements diphasiques horizontaux sont la tension superficielle, la pesanteur et le cisaillement interfacial. Les forces de tension superficielle agissent pour garder la paroi de tube mouillé et la force de pesanteur

tire le liquide en bas et rend la vapeur flottable. Le cisaillement interfacial résulte des différences entre les vitesses des phases, ce qu'on appelle le glissement. Lorsqu'on augmente le débit du gaz dans un écoulement diphasique horizontal, on constate successivement les configurations suivantes [2] :

Ecoulement à bulles (Bubbly flow), la phase de vapeur est distribuée sous forme de bulles discrètes dans une phase continue de liquide. La taille des bulles n'approche pas le diamètre de tube. Les bulles se déplacent à la partie supérieure du tube à la même vitesse que le liquide.

Ecoulement à poches (plug flow), c'est un écoulement intermittent qui se produit à de bas débits de gaz et à un débit liquide modéré. Dans ce régime, des poches de liquide et de gaz se déplacent alternativement à la partie supérieure du tube. L'écoulement à poches se nomme également écoulement de bulles ovales.

Ecoulement stratifié (stratified flow), le liquide s'écoule à la partie inférieure du tube (dans des conditions normales de pesanteur) et le gaz au-dessus. L'interface est lisse. Ce régime d'écoulement se produit à de basses vitesses de liquide et de gaz.

Ecoulement à vagues (wavy flow), à mesure que la vitesse de gaz augmente, des ondulations se forment sur l'interface liquide-gaz et elles se déplacent dans la direction de l'écoulement L'amplitude des ondulations dépend de la vitesse relative entre les phases et les propriétés du fluide, telles que sa densité et sa tension superficielle.

Ecoulement à bouchons (slug flow), quand la vitesse de gaz augmente dans un écoulement à poches, le liquide forme des bouchons. L'écoulement est plus désordonné comparé à l'écoulement à poches et l'interface entre le gaz et le liquide n'est pas nettement définie. L'écoulement à poches et l'écoulement à bouchons sont souvent considérés comme un seul régime d'écoulement appelé écoulement intermittent.

Ecoulement annulaires (annular flow), un film de liquide se forme sur la paroi du tube. Habituellement, le film liquide en bas du tube est beaucoup plus épais que le film au-dessus. La distribution de l'épaisseur de film dépend de la vitesse de gaz.

Ecoulement dispersés (spray flow), ceci se produit quand tout le liquide est entraîné par la vitesse élevée du gaz dans un noyau de gaz. La phase de vapeur est la phase continue et le liquide forme un brouillard dans le gaz (des gouttelettes pulvérisées qui peuvent être trop petites pour être vues).

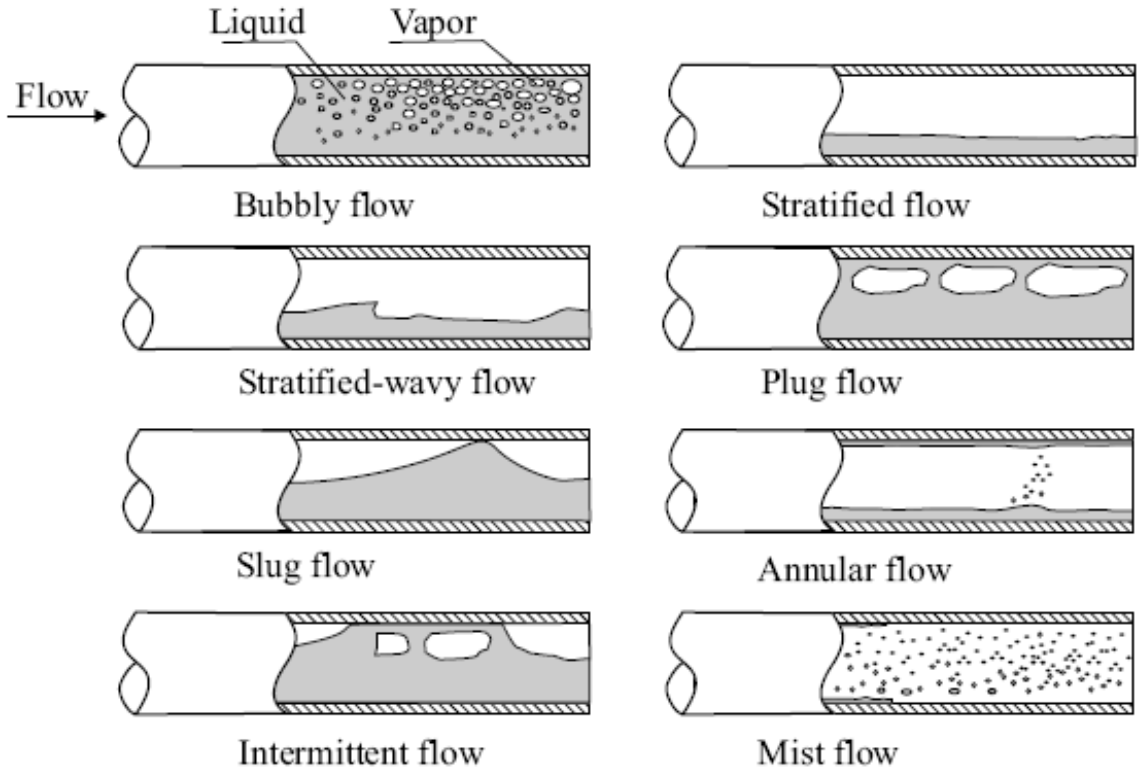


Figure I.2. Configurations de l'écoulement horizontal [2]

I.4.1.2. Configuration d'écoulement verticale

Considérons un tube vertical chauffé uniformément sur toute sa longueur avec un débit constant du liquide sous-refroidi à l'entrée, la chaleur est transférée au liquide sous-refroidi en termes de convection forcée monophasique [3]. La figure I.3 présente les différentes configurations du mélange eau-vapeur, les régimes ainsi que l'évolution des températures de la paroi et du fluide le long du tube. On distingue plusieurs régions :

Région A : dans la partie inférieure du tube, la température de la paroi et de la température du liquide augmentent. Tant que la température de la paroi n'atteint pas la valeur minimale requise pour déclencher la nucléation, les transferts de chaleur se font par convection forcée phase liquide. Cet écoulement peut être laminaire ou turbulent.

Région B : à une côte donnée de la paroi chauffante, la température de la paroi devient suffisante pour déclencher la nucléation *(*ONB pour Onset of Nucleate Boiling en Anglais*)*. A cette côte débute l'ébullition nucléée sous saturée associée à un changement de configuration d'écoulement avec l'apparition de l'écoulement à bulles (bulles attachées à la paroi dans un premier temps). La température du liquide à la paroi est alors supérieure de quelques degrés à la température de saturation tandis que la température du liquide au cœur de l'écoulement tend vers la température de saturation.

Région b1 : dans un premier temps, un nombre réduit de sites de nucléation est actif et par conséquent, peu de bulles apparaissent sur la paroi. Elle est située tout de suite après l'*ONB*. Au fur et à mesure que l'écoulement progresse plus en aval du point de déclenchement de l'ébullition nucléée, les conditions thermodynamiques pour la nucléation deviennent plus favorables avec l'augmentation du nombre de sites actifs de nucléation. Le critère de démarrage de l'ébullition nucléée est associé à une température minimum de la paroi $T_{w,ONB}$. L'ébullition nucléée sous saturée est dite partielle.

Région b2 : située en aval de l'ébullition partielle, elle est initiée à partir du moment où les premières bulles de vapeur décollent de la paroi. Elle correspond donc à un changement de configuration d'écoulement caractérisé par le décollage des premières bulles de vapeur de la paroi *(OSV* pour *Onset of Significant Void* en Anglais*)* et une nette prédominance des transferts de chaleur par nucléation (vaporisation et conduction instationnaire). La nucléation devient si importante qu'elle est équivalente au processus de nucléation dans un liquide au repos saturé. Le critère d'apparition significative de la vapeur correspond à une température du liquide minimum $T_{l,OSV}$. L'ébullition est dite pleinement développée.

Région C : elle correspond à l'ébullition nucléée saturée. La transition avec la région précédente se situe à l'endroit où la température moyenne du liquide atteint la température de saturation. L'écoulement à bulles occupe toute la section droite de la conduite. Les bulles finissent par se rassembler en de gros bouchons créant des conditions nettement discontinues. Le coefficient d'échange est amélioré par rapport à l'ébullition en vase clos à cause de l'effet de l'arrachement des bulles provoqué par la vitesse. Pour un flux de chaleur suffisamment important, il peut se produire une vaporisation locale du film liquide qui l'isole de la paroi ; une tache sèche peut se former et entraîner la destruction de la paroi (en anglais " burn out").

Région D : les bouchons se rejoignent en un cœur de vapeur continu, la paroi est baignée par un mince film annulaire de liquide, d'où le nom de l'écoulement annulaire. La température de la paroi diminue et ne permet plus de maintenir la nucléation.

Région E : l'épaisseur du film décroît au fur à mesure que l'évaporation augmente jusqu'à la rupture de ce film. C'est le phénomène d'assèchement accompagné d'une élévation brutale de la température de la paroi. La région d'écoulement à gouttelettes est appelée région déficitaire en liquide. C'est un écoulement de vapeur avec fines gouttelettes liquide entraînées (bien que certaines puissent se redéposer).

Région F : l'écoulement monophasique vapeur apparaît lorsque toutes les gouttelettes se sont évaporées. L'échange thermique s'effectue alors par convection monophasique dans la vapeur.

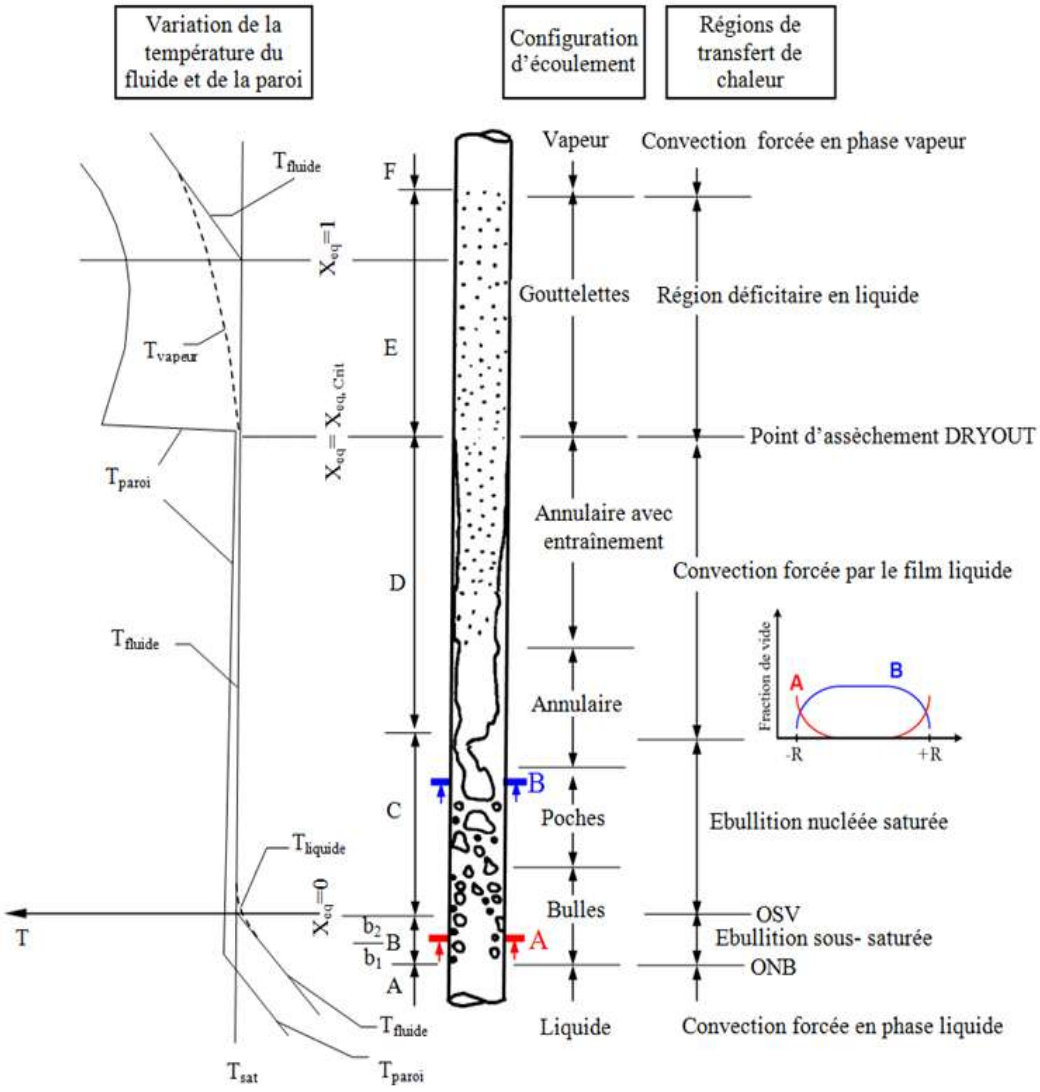


Figure I.3. Evolution des configurations d'écoulement, des températures et des régimes thermiques dans un tube vertical chauffant [3]

I.5. La crise d'ébullition

Dans les systèmes à flux de chaleur imposés (refroidissement des cœurs des réacteurs nucléaires, moteur à combustion interne, tubes électroniques, …) l'élément chauffant peut alors atteindre des températures supérieures à son point de fusion et se dégrader brutalement. Cet état de destruction ou limite de destruction est désigné par collier (1971, 1981) par le terme «burnout ». La limite de destruction survient généralement avec un certain retard par rapport aux limites de la caléfaction (DNB) et de l'assèchement «dryout». Le terme de flux thermique critique « Critical Heat Flux (CHF)» est utilisé pour désigner les deux types de crise d'ébullition. Les conséquences de la crise d'ébullition à faible titre sont beaucoup plus graves que l'assèchement. Les principaux mécanismes conduisant à son apparition sont au nombre de trois (voir la figure ci-après)

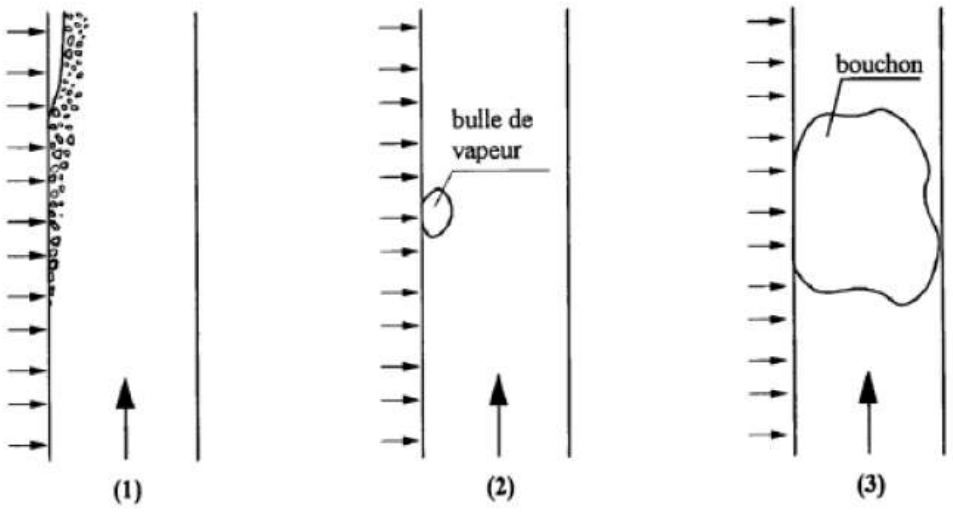


Figure I.4. Différents mécanismes de crise d'ébullition à faible titre ''caléfaction'' [5]

L'accumulation des bulles de vapeur près de la paroi chauffante. Le recouvrement de la paroi par bulles empêche tout contact avec le liquide.

Des efforts de surchauffe locale de la paroi aux emplacements des sites de nucléation dues à la formation et à l'accroissement des bulles de vapeur, sous des conditions défavorable à leur détachement.

Formation des taches sèches pendant le passage de gros bouchons de vapeur en régime d'écoulement avec bouchons.

L'assèchement est moins dangereux si l'on compare à la caléfaction en termes d'impact brutal sur les matériaux, mais à long terme, il peut provoquer la fatigue des matériaux. La configuration de l'écoulement menant à la crise d'ébullition est de type annulaire, constituée d'un film liquide en contact avec la paroi et d'un cœur de vapeur contenant des gouttelettes. L'échange de chaleur est effectué par convection forcée au travers du film liquide conduisant à l'évaporation progressive de celui-ci ; l'assèchement est alors consécutif à la vaporisation complète de ce film et conduit à une configuration d'écoulement de type écoulement à gouttelettes.

I.6. Ebullition des nanofluides

I.6.1. Notions sur les nanofluides

Les fluides caloporteurs de base souvent utilisés dans les applications de refroidissement ou de chauffage ont des conductivités thermiques très faibles qui limitent parfois leur capacité de transfert de chaleur. L'utilisation des nanofluides, particules de taille nanométrique de conductivité thermique très élevée en suspension dans un fluide caloporteur, est susceptible d'apporter des gains en performances thermiques très importants. De nombreuses recherches ont été menées sur cette

nouvelle génération de fluides afin d'apporter une meilleure compréhension des mécanismes physiques mis en jeu lors de l'utilisation des nano-fluides, et mettre ainsi au point des liquides caloporteurs plus performants.

Une nanoparticule est un assemblage de quelque centaine à quelques milliers d'atomes conduisant à un objet dont au moins l'un objet dont au moins l'une des dimensions est de taille nanométrique (1-100 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 et appliqué, et sont très étudiées actuellement [5].

I.6.2. Préparation 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 parl'utilisation de ces dernies tel que le problème de sédimentation des particules, l'augmentation des pertes de charge *etc*…. tandis que pour des particules de l'ordre du nanomètre (10^{-9} m), ces problèmes sont pratiquement insignifiants.

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

La méthode à une seule étape : basée sue la vaporisation d'un matériau solide sous vide, puis condensation directe de sa vapeur dans le liquide.

La méthode à deux étapes : elle consiste d'abord à la fabrication d'une nanopoudre sèche, puis le mélange et la dispersion de celle-ci dans le liquide.

Ces procèdes de fabrication sont la nature physique ou chimique. Ils font l'objet de beaucoup de recherches pour améliorer le cout de production qui reste toutefois élevé vu les difficultés de mise en œuvre et pour obtenir des particules de taille voulue. Chaque méthode a ses inconvénients et certaines ne sont pas aptes à produire de grandes quantités de nanoparticules pour une production de masse vu les contraintes inhérentes au procédé, notamment les méthodes en une étape (Figure I.5). Les principaux moyens peuvent être [5] :

- La mécano synthèse (broyage à haute énergie) ;
- La précipitation chimique (réduction de sels métalliques par exemple) ;
- Les dépôts chimiques ou physiques en phase vapeur (CVD ou PVD) ;
- Les dépôts chimiques en phase vapeur assistés par plasma (PECVD) ;

- La condensation de vapeurs par détente brutale dans des tuyères supersoniques ;
- La pulvérisation cathodique radiofréquence ;
- La sublimation par ablation laser (vaporisation d'un échantillon par impulsion laser) ;
- La pyrolyse laser (interaction entre un faisceau laser continu et un flux de réactifs) ;
- La désintégration d'électrodes submergées par passage d'étincelles (comme pour un usinage par électroérosion).

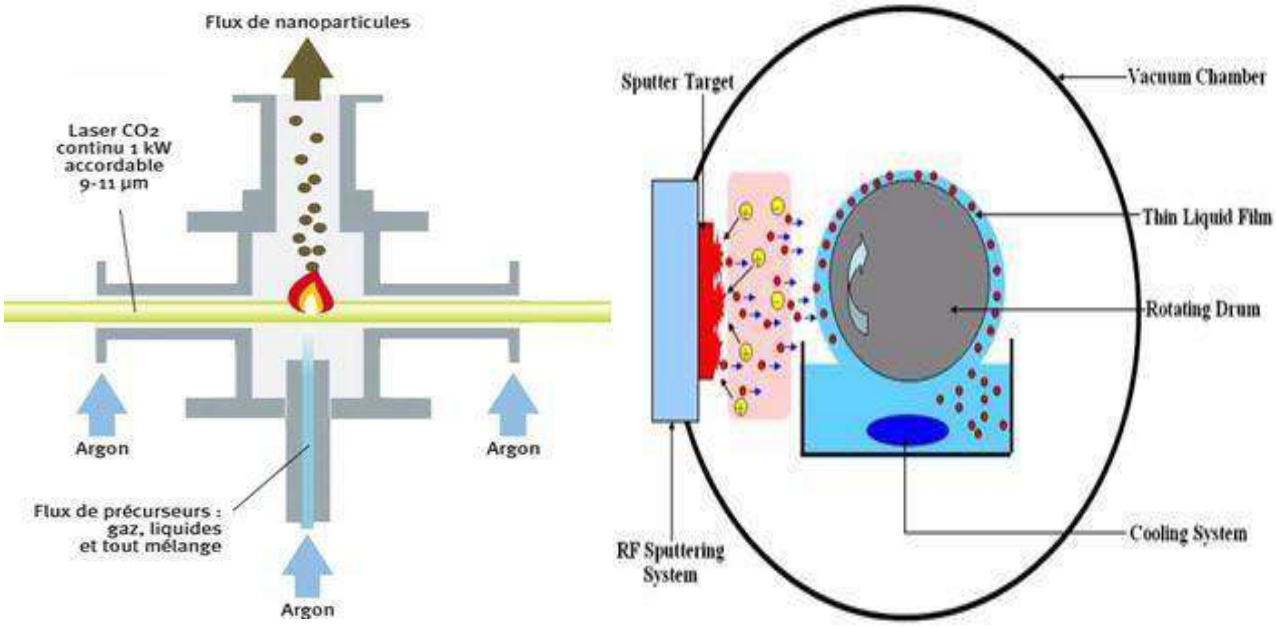


Figure I.5. Pyrolyse laser donnant de la nanopoudre à mélanger au liquide et dépôt direct dans le liquide par pulvérisation cathodique sous vide [5]

Par contre pour les procédés de fabrication de nanoparticules sont nombreux. Ils peuvent être classés en deux catégories [6] :

- Les procédés physiques, comme le broyage mécanique ;
- Les procédés chimiques, comme la pyrolyse ou la précipitation chimique ;
- Les nanoparticules des oxydes métalliques : l'oxyde d'aluminium (Al_2O_3), l'oxyde de cuivre CuO, l'oxyde silicium SiO_2 ;
- Les nanoparticules métalliques sont : l'aluminium (Al), le cuivre (Cu), l'or (Au), l'argent (Ag).

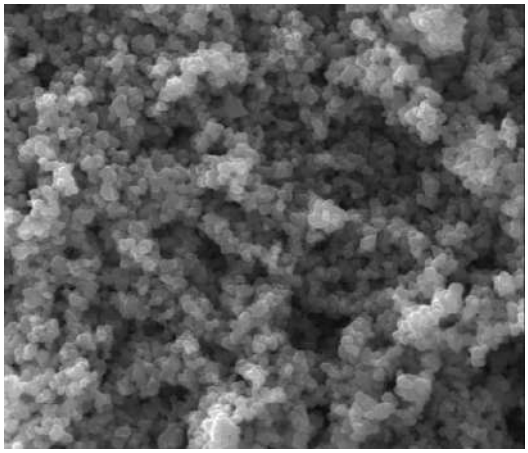


Figure I.6 Nanoparticule (Ag) [6]

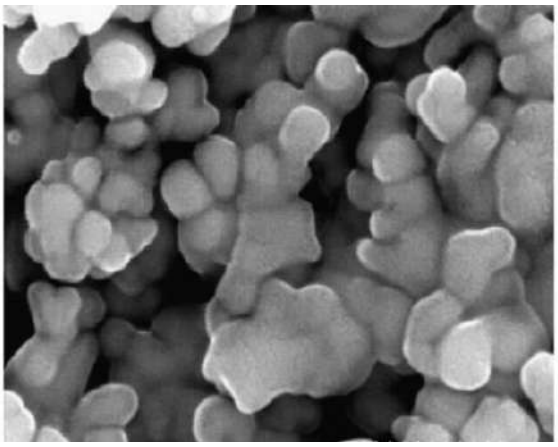


Figure I .7.Nanoparticule (TiO_2) [6]

- Les nanoparticules non métalliques : les nanotubes (CNT), le diamant (C).

D'une manière générale, les nanoparticules peuvent être classées selon leur forme en deux grandes catégories (figure I.8) :

Les nanoparticules sphériques pour lesquelles plusieurs types de matériaux peuvent être utilisés pour leur fabrication. Ces nanoparticules sphériques peuvent ainsi être à base de métaux (cuivre Cu, fer Fe, or Au, argent Ag…) ou d'oxydes de cuivre (oxyde d'aluminium Al_2O_3, oxyde de cuivre CuO, oxyde de titane TiO_2…).

Les nanotubes (les nanotubes de carbone NTC, les nanotubes de titane TiO_2, Nanotube de silicium…)

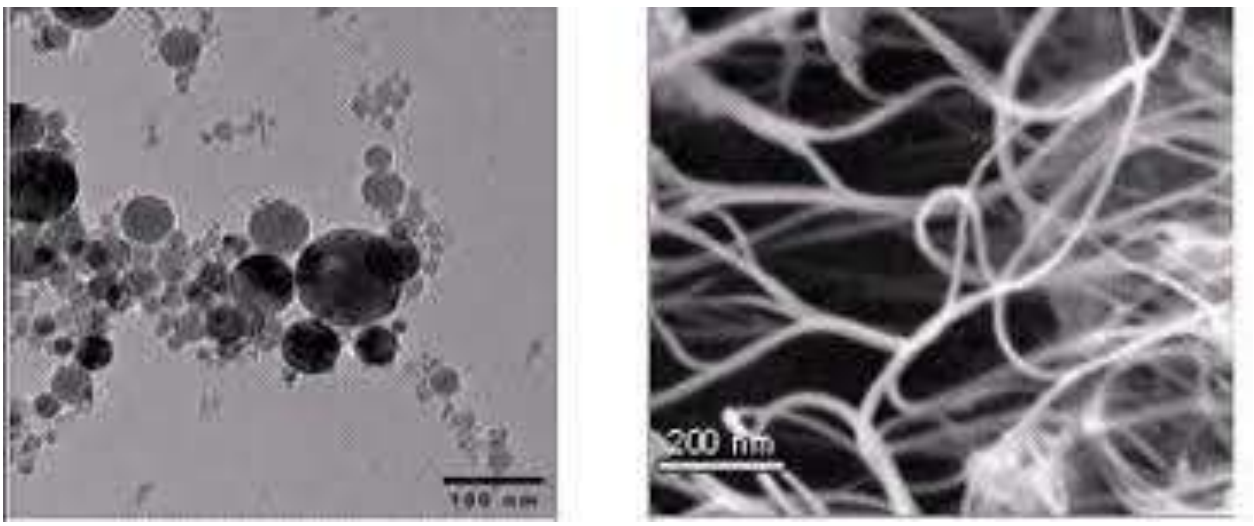


Figure I.8. nanoparticules sphériques; Nanotubes de carbone (INT1) [6]

Les liquides de base les plus utilisés : l'eau, l'éthylène glycol, les huiles, les fluides de réfrigération (R12, R22).

I.6.3. Caractéristiques thermo physiques des nanofluides

Les propriétés thermophysiques (conductivité thermique, viscosité dynamique et cinématique, capacité thermique massique, etc.) des solutions sont profondément modifiées par l'ajout de nanoparticules et un grand nombre de paramètres peuvent avoir un effet non négligeable sur cette déviation (le matériau, la taille, le rapport d'aspect, la concentration des particules en suspension, la conductivité du fluide de base, la température du milieu, etc.). De nombreux groupes de recherche tentent de comprendre quels sont le ou les mécanismes à l'origine de telles différences mais aucune phénoménologie n'a pu être encore formulée de manière concise et satisfaisante [6].

Plusieurs auteurs ont étudié le comportement des nanofluides en ébullition au niveau du coefficient d'échange ainsi que de la densité de flux critique en ébullition (CHF).

De plus, des dispositifs diphasiques de transfert thermique ont été testés avec différents fluides tels que des caloducs, des thermosiphons diphasiques et des LHP (loop heat pipe).Concernant le CHF, une augmentation importante (entre 200 et 300 %) a été confirmée par plusieurs études [7, 8] attribuée à une modification de l'état de surface par les particules.

Pour le coefficient d'échange, le tableau est plus contrasté. Certains auteurs observent une diminution, d'autres une augmentation du coefficient d'échange en évaporation.

Des améliorations de performance sont par ailleurs été observées sur des dispositifs diphasiques complets. Ce domaine en est toujours à la phase de recherche, afin de comprendre les phénomènes mis en jeu et l'influence de divers paramètres : ébullition nucléée ou évaporation en film, influence du mouillage et de la tension superficielle, de la nature des fluides et matériaux mis en jeu, de la nano-structuration de paroi induite par les nano-fluides.

L'utilisation des nanofluides en tant que fluide thermique est un nouveau domaine qui est encore en phase de recherche. Des améliorations d'échange thermique de l'ordre de plusieurs dizaines de pourcent semblent possibles, notamment pour certaines applications : moteurs thermiques et refroidissement électronique. Néanmoins, compte tenu de l'augmentation de viscosité due aux nanoparticules, le bilan énergétique reste encore mitigé. Compte tenu des diverses méthodes de synthèse et de caractérisation, les résultats expérimentaux ne sont pas reproductibles entre les différents groupes de recherche travaillant sur le sujet. En évaporation et condensation, l'intérêt des nanofluides est évident pour augmenter le flux critique en ébullition, mais la compréhension des phénomènes en ébullition et évaporation, qui ont un intérêt industriel important, reste un terrain relativement vierge.

I.7. Effets paramétriques sur l'ébullition

I.7.1. Pression des systèmes

Une augmentation de la pression décale vers la gauche la courbe de Nukiyama correspondant à l'ébullition nucléée, voir la figure I.1, le liquide utilisé est le n-pentane ; de plus, quand la pression *p* augmente, la densité de flux thermique critique croît puis décroît. Pour l'eau, la valeur maximale de la densité de flux thermique critique est de l'ordre de 4,45 MW/m² pour une pression de 70 bars, indiqué sur la figure I.9**.**

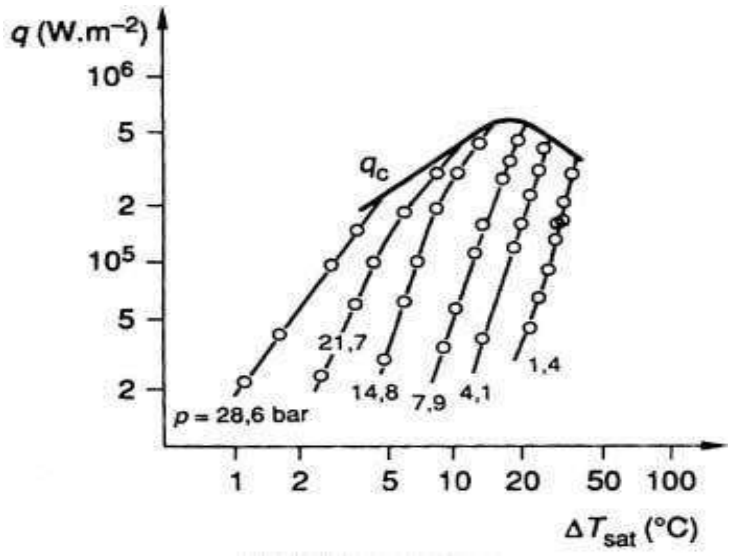


Figure I.9. Effet de la pression du système sur l'ébullition nucléée [9]

I.7.2. La gravité

Une augmentation de l'accélération de la pesanteur n'a pas une influence considérable en ébullition nucléée contrairement à l'effet en g ½ suggéré par la corrélation de Rohsenow. En revanche, les dépendances en $g^{1/4}$ des densités des flux thermiques maximal et minimal et du flux thermique en ébullition en film sont bien vérifiées par les expériences [9].

I.7.3. Gaz dissous

La présence de gaz dissous entraîne la formation de bulles de dégazage avant l'apparition de l'ébullition nucléée. Le coefficient d'échange de chaleur s'en trouve augmenté.

I.7.4. La rugosité

Une augmentation de la rugosité décale vers la gauche la courbe de Nukiyama correspondant à l'ébullition nucléée (figure I.10), En revanche l'effet de la rugosité sur le flux thermique critique n'est pas clairement établi

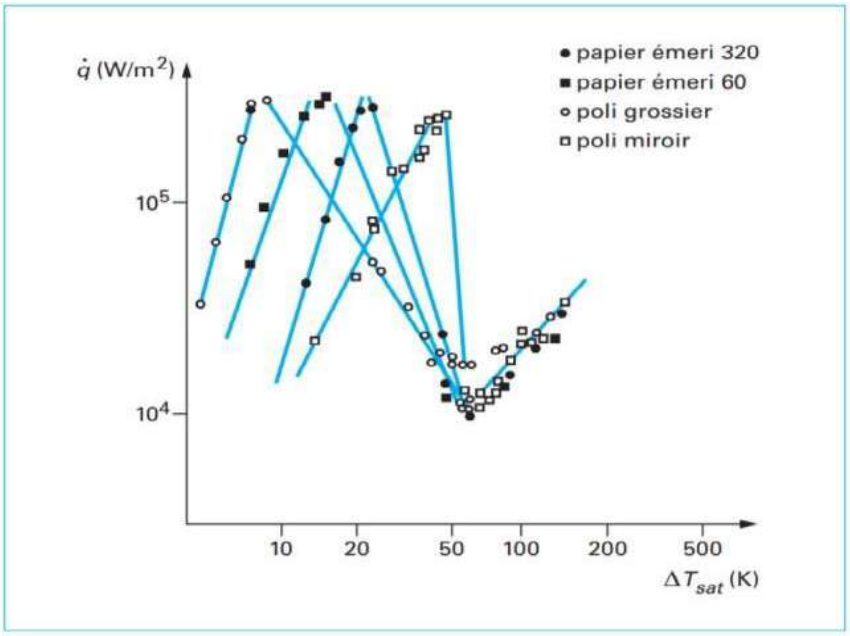


Figure I.10. Effet de l'état de surface de l'élément chauffant [10]

I.7.5. La sous saturation

Si la température du liquide loin de l'élément chauffant est inférieure à la température de saturation, la courbe de Nukiyama n'est pratiquement pas modifiée dans la zone de l'ébullition nucléée. En revanche, une augmentation de la sous-saturation accroît les densités de flux thermique maximal et de flux thermique minimal de façon significative et décale vers la gauche la courbe de Nukiyama correspondant à l'ébullition en film**.**

I.8. Grandeurs caractéristiques d'un écoulement diphasique

I.8.1. La température de saturation

C'est la température pour laquelle il y a équilibre entre la phase liquide et la phase vapeur pour une pression donnée, à condition que la pression soit constante à une valeur inférieure à la pression critique. On l'appelle aussi température d'ébullition parce que l'ébullition ou la condensation se produit à cette température qu'on note T_{sat}.

I.8.2. La pression de saturation

La pression de saturation P_{SAT} est la pression pour laquelle l'ébullition ou la condensation se produit pour une température donnée.

I.8.3. La surchauffe

La surchauffe représente la quantité positive entre la température T_w de la paroi et la température de saturation T_{sat}.

$$\Delta T_{SAT} = T_W - T_{SAT} \tag{I.1}$$

I.8.4. Le sous refroidissement

Le sous refroidissement représente la quantité positive entre la température de saturation T_{SAT} et la température T_W de la paroi.

$$\Delta T_{Sub} = T_{SAT} - T_W \tag{I.2}$$

I.8.5. Le taux de vide

Pour une section A perpendiculaire à l'écoulement, la fraction de vide est le rapport entre la surface occupée par la vapeur A_G sur la surface totale de la section occupée par la vapeur et le liquide.

$$A = A_G + A_L \tag{I.3}$$

$$\alpha = \frac{A_G}{A} \tag{I.4}$$

I.8.6. Le titre massique

Le titre massique ou réel est égal au rapport du débit massique de la vapeur sur le débit massique total.

$$X = \frac{\dot{M}_G}{\dot{M}} \tag{I.5}$$

I.8.7. Le titre thermodynamique

Il est caractérisé par la quantité de gaz calculée pour les écoulements diphasique (liquide-vapeur) avec changement de phase**.**

$$X_{th} = \frac{i(z) - i_{Ls}}{i_{GS} - i_{Ls}} = \frac{i(z) - i_{Ls}}{i_{LG}} \tag{I.6}$$

où i_{LS} et i_{GS} sont les enthalpies spécifiques du liquide et de vapeur à l'état de saturation ;

i_{LG}: est la chaleur latente de vaporisation;

i(z) : est l'enthalpie spécifique du fluide au point z;

D'après les définitions de X et X_{th} on notera que :

Pour un écoulement monophasique de liquide sous-saturé :

($T_L < T_{SAT}$) : X = 0 et $X_{th} < 0$

Pour un écoulement monophasique de vapeur surchauffée :

($T_G > T_{SAT}$) : X = 1 et X_{th} >1

Pour un écoulement diphasique de liquide et de vapeur avec :

$T_L = T_G = T_{SAT}$: $X=X_{th}$

I.8.8. Le titre volumique

C'est le rapport du débit volumique de vapeur au débit volumique totale

$$\beta = \frac{Q_G}{Q} \tag{I.7}$$

où Q et Q_G sont le débit volumique total et de la phase de vapeur respectivement.

I.8.9. Le débit spécifique

C'est le rapport du débit massique total à la section de passage.

$$G = \frac{\dot{M}}{A} \tag{I.8}$$

I.9. L'ébullition dans les réacteurs nucléaires

Une centrale nucléaire est destinée à extraire l'énergie dégagée par les réactions de fission des noyaux de combustible nucléaire (le plus fréquemment de l'oxyde d'uranium enrichi UO_2) afin de produire de l'électricité. Les différentes centrales peuvent être classes en filières nucléaires, définies par les natures du combustible, du modérateur (pour les réacteurs à neutron thermique) et du fluide caloporteur. Dans une grande majorité des réacteurs nucléaires, l'eau circulant dans le cœur assure à la fois les fonctions de fluide caloporteur et de modérateur. Les filières de réacteurs les plus répandues sont en effet les réacteurs à eau sous pression (REP, ou PWR pour Pressurized Water Reactor en anglais) et les réacteurs à eau bouillante (REB, ou BWR pour Boiling Water Reactor en anglais).

I.9.1. Les réacteurs à eau sous pression (REP)

Un réacteur à eau sous pression est composé de deux circuits fermés principaux (Figure I.11). Le combustible nucléaire est disposé dans le circuit primaire, au cœur du réacteur, à l'intérieur de gaines métalliques étanches. En fonctionnement nominal, les réactions de fission en chaine provoquées par la collision entre le flux de neutrons thermiques et la matière fissile libèrent une importante quantité d'énergie thermique, récupérée par le fluide caloporteur circulant entre les gaines de combustible**.**

Dans la cuve du réacteur, le contrôle de cette réaction en chaîne est assuré par l'abaissement ou le retrait des barres de contrôle absorbantes de neutrons. La pression régnant dans le circuit primaire est comprise entre 155 et 160 bar en fonctionnement nominal, si bien que le fluide caloporteur n'atteint pas les conditions de saturation.

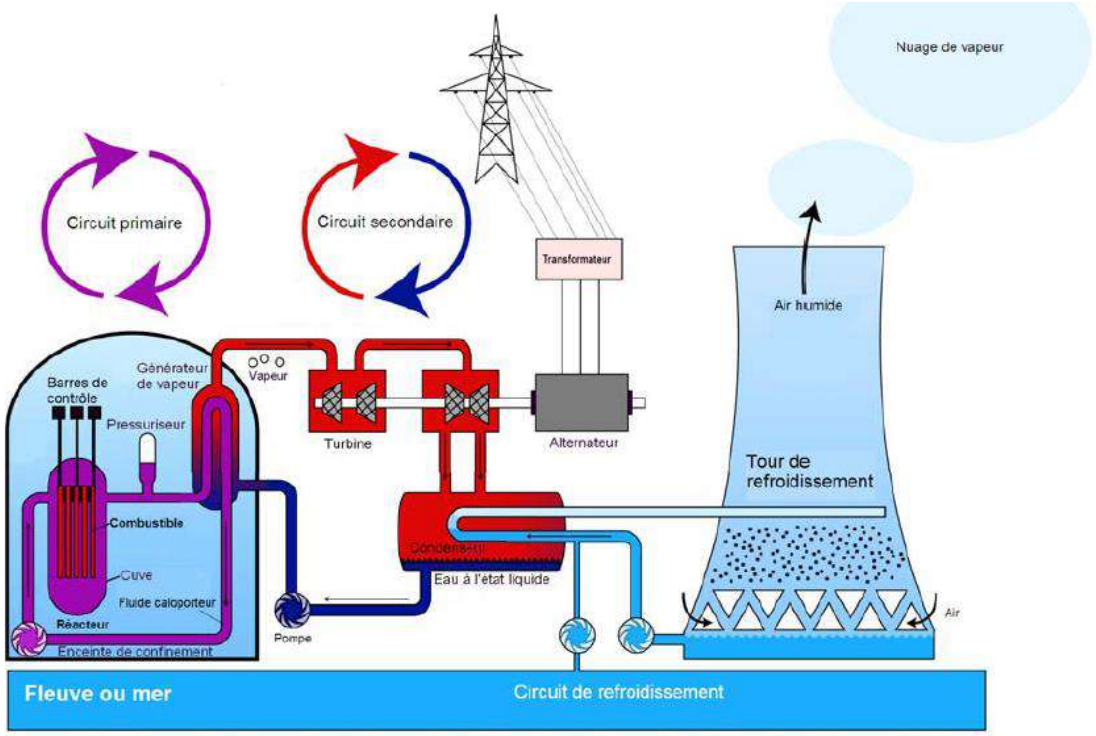


Figure I.11. Schéma de principe d'un PWR [11]

L'énergie récupérée par l'eau du circuit primaire maintenue à l'état liquide est ensuite transmise, via un échangeur de chaleur, à l'eau circulant dans le circuit secondaire à une pression plus faible. Cette eau «secondaire» est ainsi portée à ébullition ; la vapeur créée actionne alors des turbines. L'énergie mécanique produite est enfin convertie en énergie électrique grâce à un alternateur. La vapeur secondaire est condensée grâce à un circuit ouvert annexe, d'où proviennent les panaches de vapeur visibles, s'échappant de la tour de la centrale.

I.9.2. Les réacteurs à eau bouillante (REB)

Les réacteurs à eau bouillante (REB) se différencient des REP par l'absence de circuit secondaire et le fait que l'eau se vaporise directement lors de la traversée du cœur. En effet, dans un réacteur à eau bouillante (Figure I.12), la pression dans la cuve est suffisamment faible (70 à 80 bar) pour permettre l'ébullition de l'eau primaire qui baigne les gaines de combustible. La vapeur générée à une température d'environ 300 °C est donc directement utilisée pour entraîner les turbines.

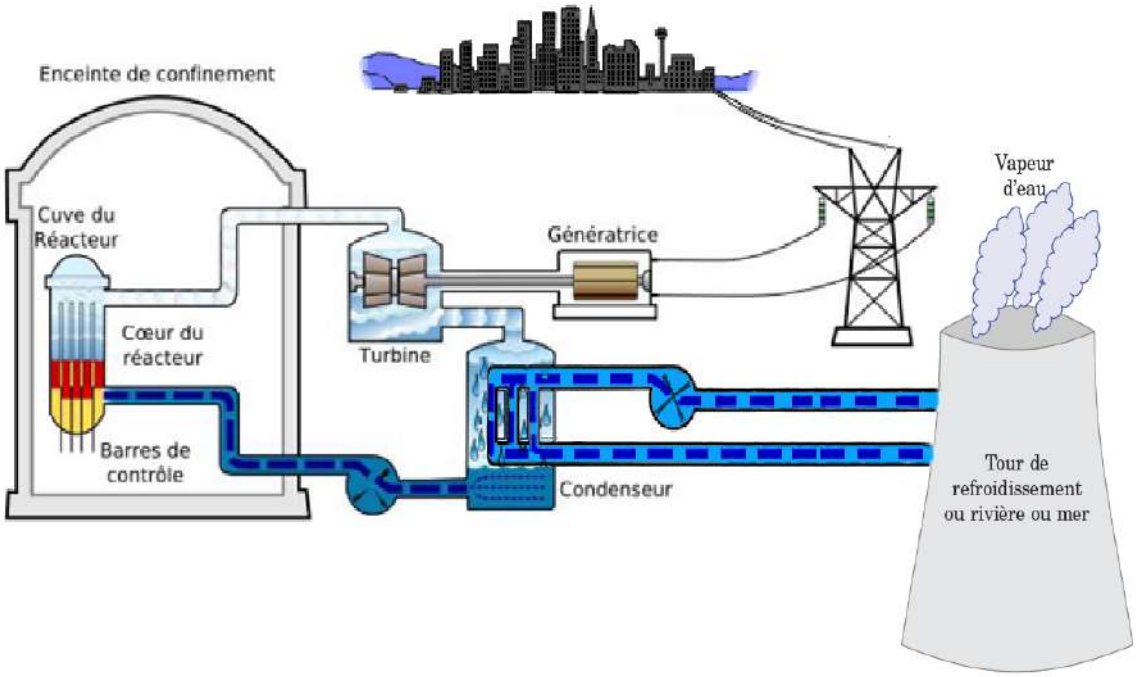


Figure I.12. Schéma de principe d'un PWR [12]

A l'instar du REP, l'eau est utilisée comme modérateur, c'est-à-dire qu'elle sert également à ralentir les neutrons afin de favoriser les réactions en chaîne. La proportion d'eau présente dans la cuve est donc un paramètre primordial ; c'est pourquoi il est nécessaire de contrôler précisément la pression interne. En effet une augmentation de la pression se traduit, du fait de la condensation, par une augmentation de la proportion d'eau liquide et donc par un accroissement de la puissance dégagée.

I.9.3. Les réacteurs nucléaires et les nanofluides

Dans un système de centrale nucléaire à réacteur à eau sous pression, (des chercheurs au-Massachusetts Institute of Technology (MIT) ont réalisé une étude visant à évaluer la faisabilité des nanofluides dans les applications nucléaires en améliorant les performances de tout système nucléaire à refroidissement par eau dont l'évacuation de chaleur est limitée. Les applications possibles comprennent le liquide de refroidissement primaire d'un réacteur à eau sous pression (REP), les systèmes de sécurité en veille, lescibles d'accélérateur, les déviateurs de plasma, etc). Le processus limitant la production de vapeur, c'est un flux de chaleur critique entre les barres de combustible et l'eau, lorsque des bulles de vapeur finissent par recouvrir la surface des barres de combustible. Très peu de chaleur par opposition à l'eau liquide. En utilisant des nanofluides à la place de l'eau, les barres de combustible se recouvrent de nanoparticules, telles que del'alumine, qui repoussent les bulles nouvellement formées, empêchant ainsi la formationd'une couche de vapeur autour de la barre et augmentant ensuite considérablement le CHF [13].

I.9.4. Sûreté des réacteurs nucléaires

La sûreté des réacteurs, visant à prévenir tout risque de contamination de l'environnement, est garantie par trois barrières de confinement de la radioactivité : la gaine des crayons de combustible, le circuit primaire, le bâtiment réacteur ou BR.

C'est pourquoi, il est nécessaire de prendre en compte, lors de la conception thermohydraulique des réacteurs, tous les phénomènes possibles pouvant affecter ces barrières, en considérant tous les régimes de fonctionnement de la centrale : nominal, transitoire ou accidentel. La figure I.13 montre la plage de la température d'opération du circuit primaire d'un PWR comparativement à un BWR.

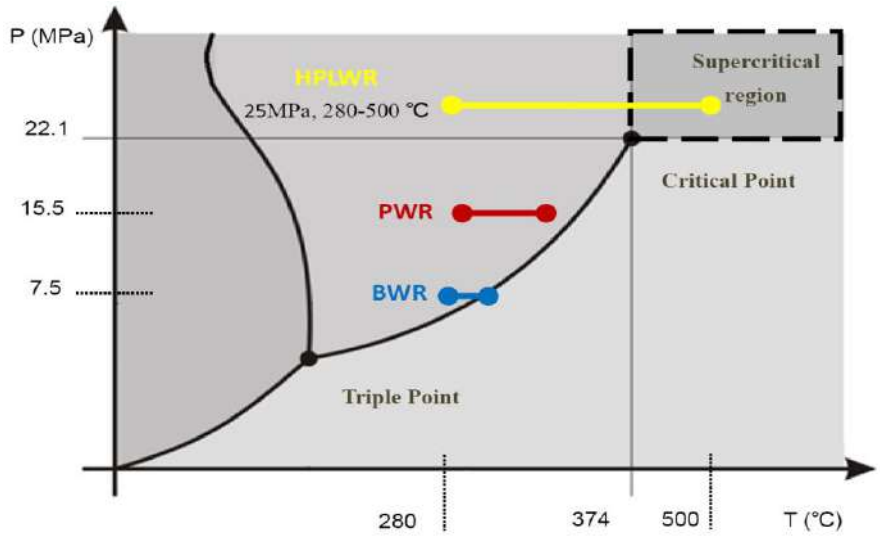


Figure I.13. Conditions d'opération d'un PWR et d'un BWR [14]

La sûreté et l'amélioration des performances des centrales nucléaires nécessitent d'avoir une connaissance précise des écoulements dans les circuits des réacteurs. La thermohydraulique, qui s'intéresse à la modélisation globale d'un réacteur dans lequel circule le fluide caloporteur, permet de comprendre le comportement du système en cas d'accident ou de prévoir son évolution à la suite d'un incident d'exploitation. La majorité des études de thermohydraulique menées aux laboratoires porte sur le comportement de ce fluide en cas d'écart au fonctionnement normal.

L'accident le plus communément envisagé pour le dimensionnement des systèmes de sûreté d'un PWR est celui de la perte du réfrigérant du circuit primaire qui refroidit le cœur du réacteur (LOCA pour Lost of Coolant Accident en Anglais). La violente dépressurisation qui en découlerait provoquerait l'ébullition de l'eau du circuit et la formation d'un écoulement diphasique (mélange d'eau et vapeur), dont il s'avère indispensable de bien prédire les caractéristiques pour déterminer avec suffisamment de fiabilité le comportement de l'installation. L'ébullition de l'eau peut se rencontrer aussi lors de l'éjection d'une barre de contrôle. Dans les deux cas, un film de vapeur,

plus mauvais conducteur de chaleur que l'eau, pourrait se former soudainement autour d'un ou plusieurs crayons. Ceux-ci seraient alors "isolés" de l'eau de refroidissement et la température du combustible pourrait atteindre très rapidement des valeurs très importantes, jusqu'à la fusion de la gaine métallique qui sépare l'uranium de l'eau (voir la figure I.9) [15].



(a) Crayon combustible



(b) Assemblage combustible

Figure I.14. Endommagement par "isolation" de la paroi chaude du liquide de refroidissement [15]

Concrètement, la maîtrise de l'extraction de la chaleur de cœurs de réacteurs nécessite l'acquisition de connaissances sur les écoulements de fluides diphasiques (c'est-à-dire des mélanges d'eau et de vapeur) que l'on étudie de l'échelle microscopique à celle du système complet. Cette étude étant très complexe, ce domaine repose en grande partie sur la modélisation et la simulation numérique [16].

Pour mieux comprendre le phénomène de l'ébullition dans le cœur d'un réacteur nucléaire, il est opportun de rappeler quelques concepts de base du fonctionnement d'une centrale nucléaire. De très nombreuses formules ont été expérimentées depuis les débuts de l'ère nucléaire industrielle mais seulement un petit nombre d'entre elles ont été sélectionnées pour les différentes générations de réacteurs opérationnels électrogènes.

I.10. Conclusion

Le transfert de chaleur lors de l'ébullition prend une place considérable dans les processus industriels vue les quantités de chaleur mises en jeux. Nous avons présenté dans ce chapitre, les phénomènes de transfert qui ont lieu pendant l'ébullition d'un liquide, les différentes configurations d'écoulement en ébullition, la crise d'ébullition, et les grandeurs caractéristiques d'un écoulement diphasique

Chapitre II

Revue bibliographique

CHAPITRE II : Revue bibliographique

II.1. Introduction

L'ébullition est la forme la plus efficace de transfert de chaleur, mais elle reste la forme la plus complexe et la moins comprise. Après des milliers d'articles publiés sur le sujet, nous ne comprenons pas encore pleinement le processus de formation de bulles et nous devons encore s'appuyer sur des relations empiriques ou semi-empiriques pour prédire le coefficient de transfert de chaleur entre une paroi chauffante et un fluide en ébullition. L'objectif de ce chapitre est de présenter une recherche bibliographique concernant l'ébullition des fluides et des nanofluides

II.2. Revues sur l'ébullition des fluides

Les méthodes de prédiction du coefficient de transfert de chaleur par ébullition utilisées jusqu'à présent sont principalement des corrélations empiriques ou semi-empiriques, car théoriquement le calcul du coefficient de transfert de chaleur de l'ébullition n'est pas encore mature. Pioro et son groupe de recherche [17], ont fait une revue de la littérature des tendances paramétriques soulignant que les principaux paramètres affectant le coefficient de transfert de chaleur en ébullition nucléée en vase sont le flux de chaleur, la pression de saturation, et les propriétés thermodynamiques du fluide. En conséquence, ces effets sur le coefficient de transfert de chaleur en vertu des conditions d'ébullition nucléée en vase ont été les plus étudiés et sont très bien établie. D'autre part, les effets des caractéristiques de surface telles que les propriétés thermodynamiques des matériaux, les dimensions, les épaisseurs, l'état de finition de la surface, les microstructures, etc., ne peuvent toujours pas être quantifiées, et d'autres enquêtes sont nécessaires. Une attention particulière doit être accordée aux caractéristiques de surfaces d'ébullition. Klaus Spindler [18] a donné une vue d'ensemble sur le comportement du transfert de chaleur d'ammoniac (R 717) en ébullition en vase. L'influence de la géométrie de surface a été discutée. Evraam Gorgy et son équipe [19] ont présenté une étude expérimentale de l'ébullition nucléée en vase du R-134a et R-123 sur des tubes lisses. Arthur E. Bergles [20] a présenté un document sur les processus de transfert de chaleur amélioré pour des flux élevés. En fait les processus de changement de phase, tels que l'ébullition en vase et l'ébullition en écoulement forcé sont des modes généralement très efficaces de transfert thermiques. les bouilleurs de recirculation, comme le montre la figure ci-dessous.

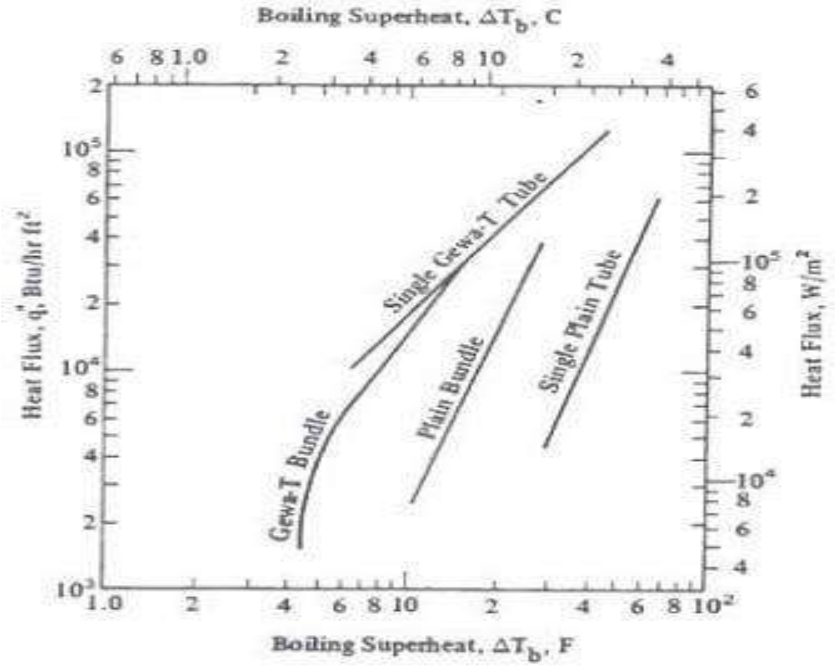


Figure II.1. Comparaison d'un tube amélioré et lisse en relation avec un faisceau de tubes [20]

Jeongbae Kim [21] a publié les résultats d'expérience de l'ébullition nucléée en vase sur une surface chauffante en utilisant du R113 pur, à l'état sous-refroidi, saturé et surchauffé ; un ensemble d'accessoires de capteurs et une caméra rapide ont été utilisés, la géométrie de la bulle a été obtenue grâce aux images capturées, le comportement de la bulle a été analysé pour les différentes conditions de l'ébullition en vase en introduisant le nombre de Jacob modifié nouvellement défini.

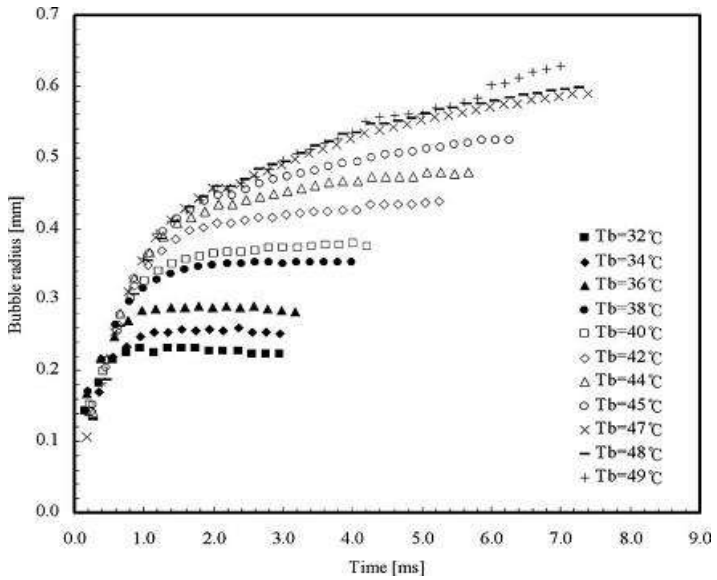


Figure II.2. Rayon équivalent de la bulle pour différentes températures de surface [21]

G. Sateesh [22] a présenté le rôle important du mécanisme de glissement d'une bulle sur des surfaces courbées dans l'ébullition en vase, le transfert de chaleur pour de tels cas a été analysé. Le modèle considère différents mécanismes tel que, la chaleur latente due à l'évaporation de la micro couche, la conduction transitoire due à la reformation de la couche limite thermique, la convection naturelle et le transfert de chaleur due au glissement des bulles ; les deux mécanismes, l'évaporation de la micro couche et la conduction transitoire prennent une place importante pendant le glissement des bulles qui se produit dans les géométries tels que surfaces inclinées ou tube horizontaux ; le modèle a été validé par les résultats expérimentaux de la littérature pour l'eau, le réfrigérant R134a, et le propane, le modèle a été trouvé pour bien convenir ces fluides pour un éventail de pression, le modèle montre l'importance des contributions de ces mécanismes pour différents fluides, surchauffe de la paroi et pressions.

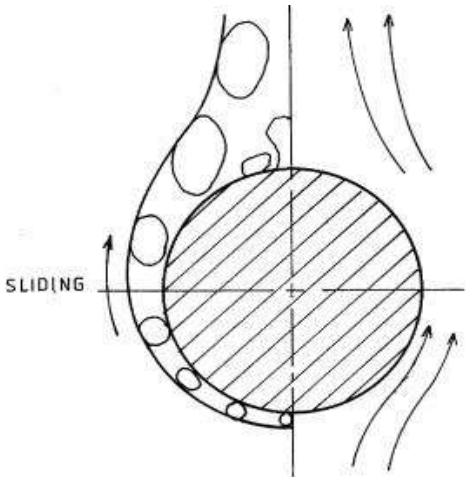


Figure II.3. Glissement d'une bulle sur un tube horizontal [22]

A.K. Das et son équipe [23], ont publié en 2009, les résultats d'une expérience ou plusieurs surfaces structurées ont été développées pour l'augmentation du transfert de chaleur pendant l'ébullition, en utilisant de l'eau distillée à la pression atmosphérique. Trois types de structures ont été testées notamment cannelure circulaire, cannelures rectangulaires et bases arrondies pour une gamme de flux de chaleur de 0 à 250 kW/m².

J. Darabi et son équipe [24], ont publié en 1999, les résultats de l'étude des deux méthodes expérimentales les plus répandues pour les expériences de l'ébullition nucléée en vase ; les données de transfert de chaleur utilisant l'eau où la méthode de chauffage électrique obtenues auprès de divers chercheurs sont comparés et discutées**.**

La méthode de chauffage électrique est une chaleur constante sur toute la longueur, alors que la méthode de chauffage de l'eau représente une température pseudo-exponentielle progressive pour l'eau de chauffage le long du tube, il a été conclu que le profil de température le long du tube est la cause principale de la différence entre les résultats des deux méthodes, les paramètres de cette forme de profil de température et les différentes causes sont discutés.

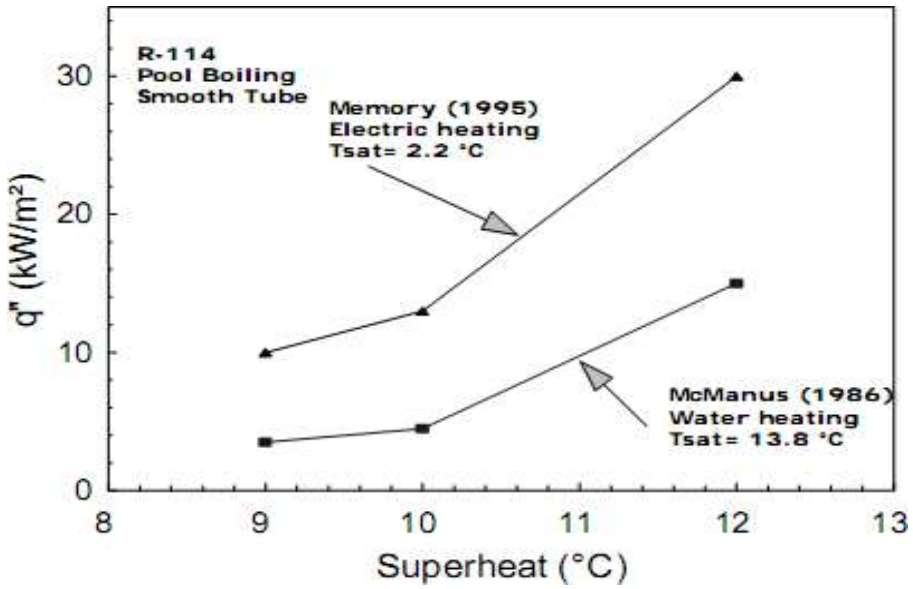


Figure II.4. Comparaison de données sur un tube tisse avec R114 [24]

Dans le régime d'ébullition nucléée, le taux de transfert de chaleur dépend fortement de la nature de nucléation (le nombre de sites de nucléation actifs sur la surface, la vitesse de formation de bulles au niveau de chaque site, etc.), ce qui est difficile à prédire. D'autre part, le type et l'état de la surface chauffée affectent également le transfert de chaleur.

Donc, il est difficile de développer des relations théoriques pour la chaleur transférée dans le régime d'ébullition nucléée ; on doit s'appuyer sur les relations basées sur des données.

La corrélation la plus largement utilisée pour le taux de transfert de chaleur dans le régime d'ébullition nucléée a été proposée en 1952 par Rohsenow [25] et exprimée par la relation :

$$\left[\frac{C_{pl}\Delta T_s}{L}\right] = C_{sf}\left[\frac{q}{\mu_{iL}}\left(\frac{\sigma}{g\left(\rho_l-\rho_g\right)}\right)^{\frac{1}{2}}\right]^n \mathrm{Pr}_l^{\,m+1} \qquad \text{(II.1)}$$

Dans cette relation, Rohsenow a introduit un coefficient C_{sf} qui tient compte du couple liquide/état de surface, l'exposant n = 0,33, m = 0 pour le cas de l'eau et 0,7 pour les autres fluides. Pour une première approximation, on prend C_{sf} égal à 0,013 quand sa valeur n'est pas connue.

Cette corrélation peut être appliquée pour différentes pressions. Le tableau II.1 montre les différentes valeurs de C_{sf} pour un couple de combinaison fluide/solide.

Tableau II.1. Valeurs de C_{sf} dans la corrélation de Rohsenow [25]

Fluide	Solide	C_{sf}
Eau	Nickel	0,006
Eau	Inox	0,012
Eau	Platine	0,013
Eau	Cuivre	0,013
Eau	Bronze	0,006
R141b	Cuivre	0.0063
Benzène	Chrome	0,010
Ethanol	Chrome	0,0027
N-pentane	Chrome	0.015

L'état de la surface de chauffe affecte grandement le transfert de chaleur et l'équation de Rohsenow donnée ci-dessus est applicable sur des surfaces nettoyées et relativement lisse.

Notant que L, l'enthalpie de vaporisation, qui apparaît dans le dénominateur de l'équation, doit avoir une influence sur l'augmentation significative du taux de transfert de chaleur à des pressions élevées pendant l'ébullition nucléé.

Dans la conception des équipements de transfert de chaleur par ébullition, il est extrêmement important pour le concepteur d'avoir une connaissance du flux de chaleur maximum, afin d'éviter le danger de dégradation de l'équipement. Le flux maximum (ou critique) de chaleur dans l'ébullition nucléée en vase a été déterminé théoriquement par S.S. Kutateladze en Russie [26] et N. Zuber aux États-Unis [27] en utilisant des approches très différentes, et est exprimé en :

$$q_c = C\,\rho_v^{\frac{1}{2}} L_{lv} \sqrt[4]{g(\rho_l - \rho_v)\sigma} \qquad \text{(II.2)}$$

Avec C = 0,131 , Zuber a trouvé la même relation avec $C = \pi/24$ = 0,1309

Où *C,* est une constante dont la valeur dépend de la géométrie du dispositif de chauffage. Lienhart et ses collègues [28] ont indiqué que la valeur de *C,* est d'environ 0,15. A Noter également que le flux maximum est proportionnel à l'enthalpie de vaporisation *L* et que degrands flux de chaleur maximum peuvent être obtenus en utilisant des fluides avec une grande enthalpie de vaporisation, tel que l'eau.

Le flux de chaleur minimal, qui se produit au point bas, est d'un intérêt pratique puisqu'il représente la limite inférieure pour le flux de chaleur dans le régime de l'ébullition pelliculaire.

En utilisant la théorie de la stabilité, Zuber a obtenu pour le flux de chaleur minimum pour une grande plaque horizontale l'expression suivante :

$$q = C\,\rho_v h_{lv} \sqrt[4]{\frac{g(\rho_l - \rho_v)\sigma}{(\rho_l + \rho_v)}} \qquad \text{(II.3)}$$

Où la constante C = 0,09 a été déterminée par Berenson [29] ; Il a remplacé la valeur théorique $\pi/24$ par 0,09 pour mieux correspondre les données expérimentales. Pourtant, la relation ci-dessus peut donner des valeurs avec une erreur de 50% ou plus.

En utilisant une analyse semblable à la théorie de Nusselt sur la condensation, Bromley [30] a développé une théorie pour la prédiction de flux thermique en ébullition pelliculaire stable à l'extérieur d'un cylindre horizontal. Le flux de chaleur sur un cylindre horizontal ou sphère de diamètre D est donnée par:

$$h = 0,62\left[\frac{g(\rho_l - \rho_v)\rho_v \lambda_v h_{lv}}{D\,\mu_v \Delta T}\right]^{\frac{1}{4}} \qquad \text{(II.4)}$$

D. A. Labuntsov [31], a développé une corrélation calculant le coefficient de transfertde chaleur en ne tenant compte que des caractéristiques thermo-physiques du liquide, en se basant sur le fait que la chaleur est transmise au liquide à travers la couche limite en contact avec la paroi chaude, cette corrélation a été comparée aux données expérimentales et a donné des résultats satisfaisant.

K. Cornwell et son groupe [32], ont été les premiers à présenter une corrélation indiquant l'influence du diamètre du tube sur le coefficient de transfert de chaleur, après une analyse théorique sur le départ des bulles autour de la circonférence, et le transfert de chaleur local, cette

corrélation a été vérifiée pour l'eau, les réfrigérants et les liquides organiques ; et ont remarqué que l'ébullition nucléée sur un tube diffère considérablement de celle sur une plaque plane.

Dans ce dernier cas, les bulles sont formées au niveau des sites de nucléation dispersés et partent prenant une partie de la couche limite surchauffée avec eux et de provoquer une éruption de liquide frais à la surface. Les effets de convection sont souvent caractérisés par le diamètre de la bulle au départ ; Dans le cas d'un tube horizontal, l'observation montre que la nucléation se produit principalement sur la face inférieure du tube et que les bulles glissent alors parallèles à la surface jusqu'à un point situé près du sommet avant leur départ. Ainsi, une bulle-couche est formée autour du tube.

P.K. Sarma et son équipe [33], ont analysé le transfert de chaleur de l'ébullition nucléée sur des tubes horizontaux, en utilisant une analyse dimensionnelle et les corrélations de différents auteurs. L'inclusion de certains paramètres sans dimension dans l'analyse a abouti à un rapprochement plus étroit avec les données expérimentales par rapport aux équations de chercheurs antérieurs. La présente corrélation a également été testée avec les données expérimentales de Borishansky et al, le transfert de chaleur au cours de l'ébullition nucléée d'eau et d'alcool éthylique, sur des tubes de diamètre variant entre 5 à 7 mm. On constate que la corrélation peut prédire les valeurs expérimentales avec un écart maximal de ±16%.

K. Cornwell et S. D. Houston [34], ont trouvé en 1994 que l'ébullition en vase sur des tubes horizontaux dirige une couche d'écoulement à bulles autour de la périphérie inférieure du tubedans lequel des bulles coulissant autour de la surface. Le transfert de chaleur est amélioré par convection de liquide à la surface autour de la bulle et par une évaporation rapide d'une couche mince sous la bulle en glissement. Ces deux mécanismes sont une fonction de la vitesse d'écoulement de vapeur et une corrélation a été développée, en fonction de la pression et du diamètre du tube. La corrélation s'applique à l'eau, aux fluides frigorigènes et organiques bouillant sur les tubes de 5-50 mm de diamètre. Compte tenu de la grande dispersion trouvée dans des expériences d'ébullition en vase, la corrélation correspond bien aux données disponibles dans la littérature et est particulièrement adaptée pour une utilisation dans les calculs de conception des équipements.

Gang et al. [35] ont étudié expérimentalement l'effet d'orientation sur le coefficient de transfert de chaleur d'une surface descendante pour un écoulement en ébullition dans un canal rectangulaire à faible débit. Ils ont développé une nouvelle corrélation de coefficient de transfert de chaleur basée

sur la corrélation de Liu et Winterton [36] en considérant l'effet d'orientation, une autre nouvelle corrélation a été développée par Kouidri et al. [37] pour le coefficient de transfert thermique moyen lors de l'ébullition en écoulement dans un canal rectangulaire valable pour un nombre de Reynolds compris entre 380 et 1522 et pour un flux thermique compris entre 9 et 137 [KW m-2]. L'effet d'orientation sur le coefficient de transfert de chaleur d'un écoulement en ébullition pour le FC-72 dans un microcanal chauffé a été étudié par Piasecka et al. [38], ils ont montré que le HTC est plus élevé pour un angle d'orientation égal à 90º ils ont également montré que pour une qualité inférieure l'effet d'orientation est important.

Chen [39] a développé un nouveau modèle pour l'estimation du coefficient de transfert de chaleur pour un écoulement saturé en ébullition dans un tube verticale, le modèle est basé sur la combinaison du transfert de chaleur convectif et du transfert de chaleur en ébullition nucléée, leur modèle est essentiellement basé sur les corrélations de Forster-Zuber [40]. Shah [41] a proposé une corrélation pour les tubes verticaux et horizontaux, il a considéré l'ébullition convective et nucléée comme processus fondamental de transfert de chaleur. Gungor et Winterton [42] ont utilisé une grande base de données pour l'eau et d'autres fluides pour donner une autre forme de corrélation de Chen. Kandlikar [43] a développé une corrélation générale pour le HTC sur la base d'une base de données avec 5246 données expérimentales. Kim et Sohn [44] ont développé une corrélation pour le coefficient de transfert de chaleur après une étude expérimentale de l'écoulement bouillant dans un canal rectangulaire avec une large gamme de nombre de Reynolds et de flux de chaleur. Özdemir et al. [45] ont étudié expérimentalement le flux d'ébullition de l'eau dans des microcanaux rectangulaires simples.

Bromley [45] a été le premier à développer une corrélation du coefficient de transfert de chaleur pour le transfert de chaleur par ébullition pelliculaire, Hsu [46] soutient que le modèle de Nusselt pour la condensation qui constitue la base du modèle de Bromley n'est pas valide au début de la turbulence en raison de la grande différence de vitesse liquide-vapeur qui existe une fois que la turbulence commence. Dougall et Rohsenow [47] ont développé un modèle pour prédire la température de paroi locale et les coefficients de transfert de chaleur pour le transfert de chaleur par ébullition pelliculaire à l'intérieur d'un tube vertical avec un écoulement ascendant, Un modèle mécaniste pour la région d'ébullition à film annulaire inversé a été développé par Analytis et Yadigaroglu [48], Les travaux de Takenaka et al. [49] ont réalisé des expériences utilisant du R-113

et de l'azote circulant vers le haut à l'intérieur d'un tube vertical chauffé et ils ont été les premiers à produire une carte du régime d'écoulement pour l'IAFB. Les travaux de Cachard [50] s'appuient sur les travaux de Yadigaroglu et Analytics, ce travail est le travail le plus récent autour de l'ébullition en film annulaire inversé. Elias et Chambre [51] ont étudié l'IAFB à partir de surfaces verticales. L'étude prend comme base l'existence de deux régions différentes d'ébullition annulaire inversée. Hammouda et al [52] ont développé un modèle à deux fluides dans le but de prédire la température de la paroi du tube pour l'ébullition annulaire inversée (IAFB). Sindhuja et al [53] ont réalisé une expérience IAFB avec le réfrigérant R-407c et ont présenté le coefficient de transfert de chaleur pour divers débit massique, flux de chaleur et pressions, Ils ont constaté que les corrélations existantes pour le R-407c surévaluaient la valeur du coefficient de transfert de chaleur. Nakla et al [54] ont présenté une corrélation de transfert de chaleur pour le réfrigérant R-134a et ont signalé qu'en fonction de paramètres tels que le débit massique, la qualité locale et la pression.

Le Tableau II.2 présente quelques méthodes de prédiction du coefficient de transfert de chaleur d'un écoulement en ébullition de la littérature [55-66].

Tableau II.2.Methodes de prédiction du transfert thermique des écoulements en ébullition

auteurs	Les fluides	D [mm]	G [Kg/m^2 S]	T [c]
chen [55]	Water, methanole, pentane, benzene, heptane	-	50-1400	36.5-242,2
Shah[56]	Water, R11, R12, R22, R113, cyclohexane	26,2	0-40	31-150
Gungor et Wintrton[57]	Water, R11,R12, R113, R114, R22, ethyléne glycol	2,95-32	12,4-25,4	0,7-364,9
Kenning and Cooper[58]	Water	9.6-14	/	0,007-0,03
Kandlikar[59]	Water, R11, R12, R1381, R22, R113, R114, R152, Neon, Nitrogene	4,6-32	13-8179	0,04-82,4
Liu et Winterton [60]	R11, R12, R113, R114, R22, Ethylene-Glycol-butanol-Ethanol	2,95-32	12,4-87-179.3	/
Lazareck et black[61]	R113	3,1	125-170	55-97
Kattan et al[62]	R123, R134a, R402a, R404a, R502	12	100-500	1-30,7
Wojtan et al[63]	R22, R410a	8-13,84	70-700	5
Cheng et al[64]	CO_2	0,8-10	170-570	25-28
Zhang et al[65]	Water, R11, R12, R113	0,78-6	23,4-2939	0,005-0,25
Kim et Mudawar[66]	Water, R11, R113, R123, R1234yf, R1234ze, R134a, R152a, R22, R236fa, R245fa, R32, R404a,	0,19-6,5	19-1608	/

II.2.1. Modélisation de l'ébullition par RNA

La technique des réseaux de neurones artificiels (ANN) est largement utilisée pour résoudre les problèmes de transfert de chaleur en ébullition [67-71], Les réseaux de neurones artificiels sont également utilisés pour la prédiction de la conductivité thermique des fluides frigorigènes liquides et vapeurs purs et leurs mélanges binaires et ternaire [72].

La technique de réseau de neurones artificiels ANN a été utilisée pour prédire un modèle d'écoulement à deux phases gaz-liquide [73], détermination du nombre de Nusselt [74], la prédiction du transfert de chaleur dans les échangeurs de chaleur [75-79].

La technique du réseau de neurones artificiels a été utilisée par Mohammedi et al. [69] pour la prédiction des propriétés thermodynamiques de vapeur saturée et le liquide saturé. La figure II.5 représente l'évolution des articles publiés pour la prédiction du coefficient de transfert de chaleur des écoulements en ébullition par les réseaux de neurones artificielle dans la dernière décennie (en utilisant Google Scholar).

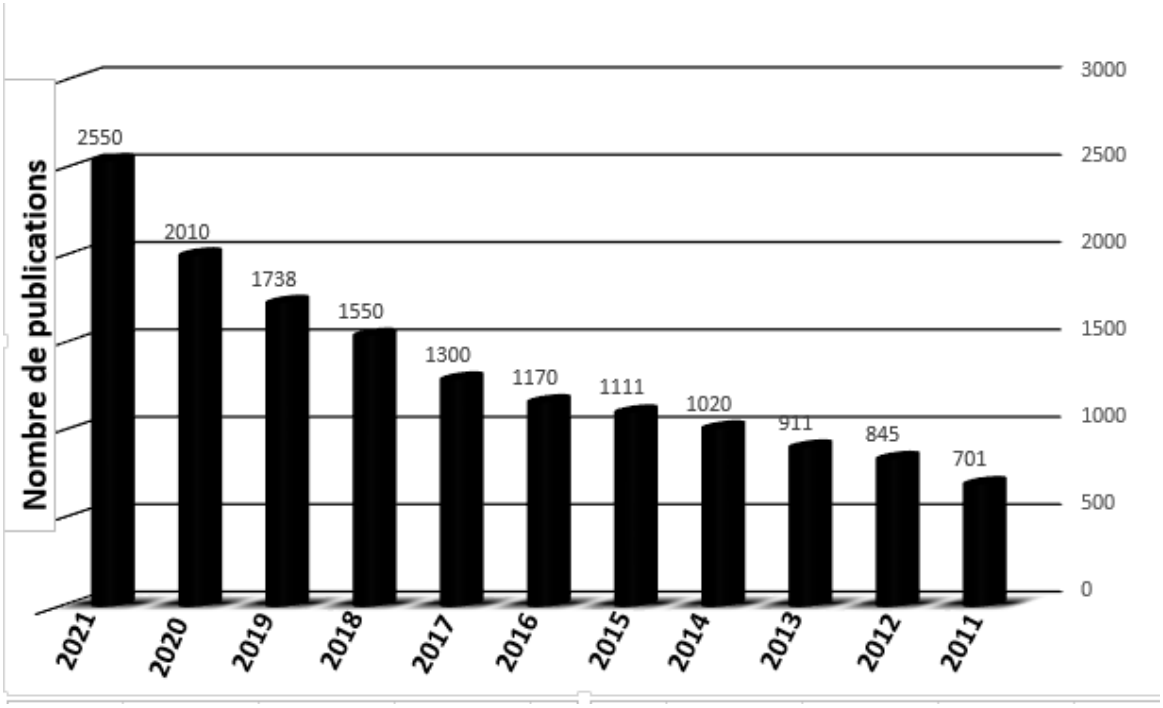


Figure II**.5. Evolution des articles publiés pour la prédiction du coefficient de transfert de chaleur pour des écoulements en ébullition des fluides par RNA**

II**.2.2. Modélisation de l'ébullition par SVM**

Les machines à vecteurs de support (SVM) sont l'une des techniques d'intelligence artificielle qui peut fournir des outils utiles pour la modélisation et la corrélation des problèmes de transfert de chaleur pratiques**.** Cette technique est également utilisée pour divers domaines d'application [80-84].

La figure II.6 représente l'évolution des articles publiés pour la prédiction du coefficient de transfert de chaleur des écoulements en ébullition par la technique de machine à vecteurs de support (en utilisant Google Scholar).

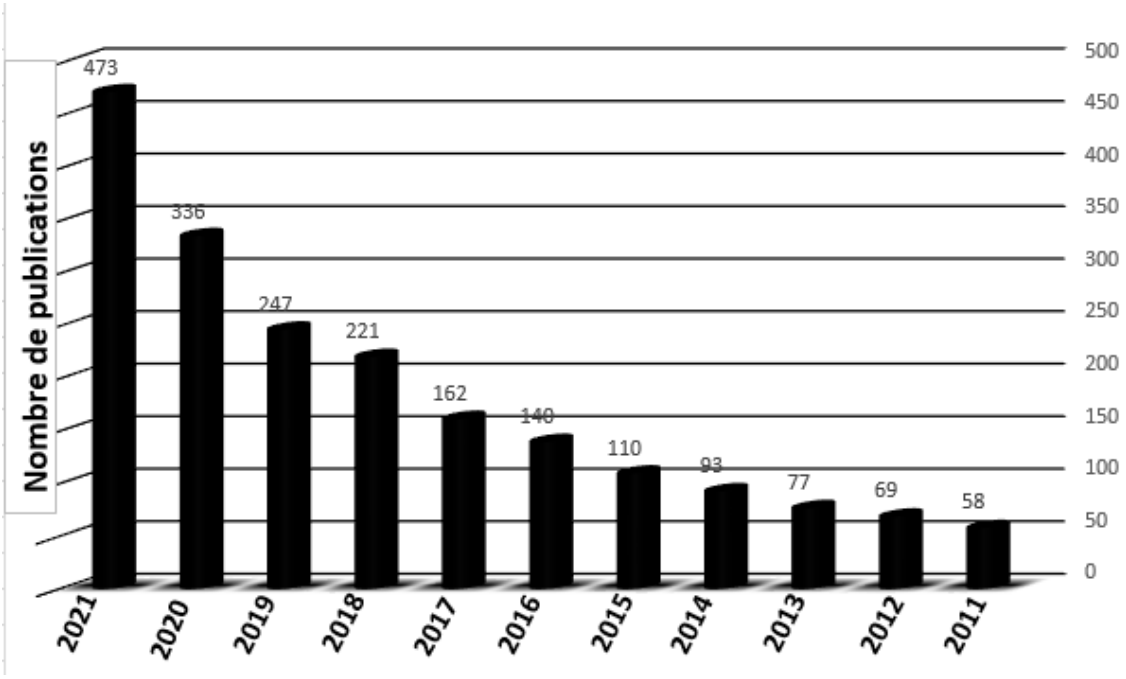


Figure II**.6. Evolution des articles publiés pour la prédiction du coefficient de transfert de chaleur pour des écoulements en ébullition des fluides par SVM**

II.3. Revues sur l'ébullition des nanofluides

Les nanosciences et les nanotechnologies ont ouvert la voie à l'émergence d'une nouvelle catégorie de fluides appelés nanofluides à la fin des années 90. La dispersion de particules solides de tailles nanométriques dans un liquide constitue un nanofluide, cette technique répondait au besoin d'améliorer les caractéristiques thermiques des fluides. Les nanofluides utilisés dans le domaine industriel pour le refroidissement des composants électroniques, le refroidissement des systèmes nucléaires, des réfrigérateurs domestiques et autres applications industrielles.

L'ébullition est un mode efficace de transfert de chaleur ; il est utilisé dans les systèmes de refroidissement du cœur nucléaire. Il existe deux principaux modes d'ébullition. Ebullition en vase ; dans laquelle la surface chauffante est immergée dans un liquide stable, et l'ébullition en convection forcée dans laquelle le liquide s'écoule autour de la surface chauffante. Le transfert de chaleur par ébullition en écoulement des nanofluides a été largement étudié au cours des dernières années. Le phénomène de transfert de chaleur dans les nanofluides est gouverner par plusieurs paramètres,

notamment la taille des nanoparticules, la forme des nanoparticules, la concentration volumétrique des nanoparticules, le type de liquide, la température du liquide et la stabilité des nanoparticules dispersées [85, 86], la résistance thermique de contact, l'agrégation de nanoparticules [87-89], et l'ajout de tensioactif [90], débit massique et flux de chaleur [91].

Les formes des nanoparticules ont une influence considérable sur l'amélioration du transfert de chaleur. Vananki et al. [92] ont déterminé l'influence des formes de nanoparticules sur l'amélioration du transfert de chaleur à l'aide de nanofluide (SiO_2-EG), ils ont constaté que le nanofluide avec une forme de nanoparticule de plaquette a la meilleure amélioration du transfert de chaleur par rapport aux autres formes de nanoparticules. Elias et al. [93] ils ont réalisé une étude numérique sur l'effet de différentes formes de nanoparticules sur les performances de transfert de chaleur dans l'échangeur de chaleur, Ils ont découvert que le nanofluide avec une forme de nanoparticule cylindrique fournit les plus grands coefficients de transfert de chaleur. Le potentiel zêta est un paramètre important dans la stabilité des nanofluides, c'est un critère qui détermine la stabilité de la dispersion des ions, de nombreuses études ont prouvé que les potentiels zêta supérieurs à 30 [mV] fournissent une suspension stable [94].

L'objectif de l'utilisation de tensioactif dans la préparation de nanofluides est d'améliorer la dispersion des nanoparticules et la perte de stabilité des nanofluides. Tian et al. [95] ont constaté que le coefficient de transfert de chaleur d'ébullition (BHTC) pour scilica-eau distillée pour tous les tensioactifs est plus grand que (BHTC) pour l'eau distillée. Almanassara et al. [96] ont utilisé trois types différents de tensioactifs (polyvinylpyrrolidone, gomme arabique et sodium dodécyl sulfate) afin de connaître leur effet sur la stabilité et les propriétés thermo-physiques des nanotubes de carbone (CNT)/nanofluides d'eau, ils ont trouvé que la gomme arabique et le polyvinylpyrrolidone a une amélioration significative des propriétés thermiques. L'influence de l'agrégation des nanoparticules sur le transfert de chaleur des nanofluides est importante. À cause de ça, Ding et al. [97] ont étudié l'effet d'agrégation de nanoparticules sur le transfert de chaleur du nanofluide de dioxyde de titane dans un tuyau, ils concluent que l'ajout de nanoparticules dans le liquide de base améliore la conduction thermique et que l'amélioration augmente avec l'augmentation de la concentration des particules et la diminution de la taille des particules. Certains chercheurs ont conclu que le dépôt de nanoparticules sur les surfaces chauffantes diminuerait la capacité de transfert de chaleur d'ébullition du nanofluide [98-101]. La résistance thermique entre la surface

chauffante et le fluide est augmentée par le dépôt de nanoparticules, le dépôt de nanoparticules provoque la diminution du site de nucléation et la détérioration du transfert de chaleur [102-104].

Sun et Yang [105] ont étudié le transfert de chaleur d'ébullition des nanofluides Cu/R141b, Al/ R141b, Al_2O_3/R141b et CuO/R141b dans des tubes horizontaux à des concentrations de 0,1, 0,2 et 0,3%. Akhavan Behabadi et al. [106] ont étudié l'influence des nanoparticules de CuO sur l'ébullition du mélange R600a/nano lubrifiant s'écoulant dans un tube horizontal lisse. Diao et al. [107] ont mené des études expérimentales sur le flux de chaleur critique et les caractéristiques d'ébullition du nanofluide Cu/R141b pour différentes concentrations volumétriques (0,008, 0,015 et 0,05%) sous pression atmosphérique sur une surface plane. Peng et al. [108] ont étudié l'influence de la taille des particules primaires et du tensioactif sur les caractéristiques d'agrégation du nanofluide TiO_2/R141b, des nanoparticules de TiO_2 de tailles 20, 40, 60 et 100 [nm] ont été dispersées dans le réfrigérant R141b. La concentration variait entre 25 et 500 [mg/L]. Les résultats ont montré que les particules peuvent atteindre un état d'équilibre au cours du temps et que le diamètre hydrodynamique dépend principalement de la taille de la particule. Yang et al. [109] mené des expériences sur un tube ondulé pour décrire les performances d'ébullition du nanofluide MWCNT/R141b. Rajabnia et al. [110] ont étudié expérimentalement l'ébullition sous-refroidie d'eau/TiO_2 nanofluide dans un tube horizontal. Le transfert de chaleur par ébullition des nanofluides SiO_2/R134a et CuO/R134a/polyolester dans un tube de cuivre horizontal a été étudié par Henderson et al. [111]. Baniamerian [112] a utilisé un modèle analytique pour simuler le transfert de chaleur et de masse dans les écoulements en ébullition des nanofluides. Manish Dadhich et al. [113] ont étudié expérimentalement le transfert de chaleur en ébullition des nanofluides Al_2O_3 et TiO_2 dans un tube horizontal. Ils ont développé deux corrélations du coefficient de transfert de chaleur qui sont basées sur la concentration volumétrique (C), le débit massique (G) et le flux de chaleur (q) pour l'eau/TiO_2 (Eq II.5) et l'eau/Al_2O_3 (II.6)

$$HTC_{TiO_2} = 0.0027 \times q^{0.15} \times C^{0.14} \times G^{1.3} \quad \text{(II.5)}$$

$$HTC_{Al_2O_3} = 0.0034 \times q^{0.16} \times C^{0.2} \times G^{1.33} \quad \text{(II.6)}$$

Mukherjee et al. [114] ont mené une étude expérimentale sur les propriétés thermo-physiques et les performances d'un écoulement en ébullition sous-refroidies des nanofluides Al_2O_3/eau dans un tube horizontal. Une étude expérimentale d'ébullition a été effectuée par Dadhich et al. [67] pour

examiner le coefficient de transfert de chaleur de l'eau et de l'eau/TiO_2 nanofluid, ils ont constaté que le coefficient de transfert de chaleur de nanofluide d'eau-TiO_2 est amélioré avec l'amélioration de la concentration volumétrique, ils ont également trouvé que le HTC de eau/TiO_2 nanofluide était plus grand que le HTC de l'eau pure.

Les caractéristiques de transfert de chaleur des écoulements en ébullition de SIC/H_2O et de graphite/H_2O nanofluides sont étudiées expérimentalement par Wang et al. [115] avec la considération du débit massique, le flux de chaleur et de la pression. Moreira et al. [116] ont étudié le coefficient de transfert de chaleur des écoulements des nanofluides et de l'eau distillée à l'intérieur des microcanaux dans des conditions près du flux de chaleur critique. Nakhjavani et al. [117] ont étudié les caractéristiques de transfert de chaleur d'un écoulement de nanofluide TiO_2/ H_2O dans un échangeur de chaleur annulaire. Hachemi et al. [118] ont réalisé une étude des caractéristiques de transfert de chaleur d'un écoulement en ébullition avec flux de chaleur critique utilisant des nanofluides de nanotubes et d'eau, Ils ont constaté que le coefficient de transfert de chaleur des nanofluides était supérieur à celui de l'eau pure.

Le Tableau II.3 récapitule les investigations expérimentales sur le coefficient de transfert de chaleur en ébullition en vase des nonofluides.

Tableau II**.3.Résumé des investigations expérimentales sur le HTC pour l'ébulition en vase des nanofluides.[119]**

Concentration du nanofluides	Dimension des Nanparticules (nm)	Taux de transfert de chaleur
Au/water, SiO_2/EG-water; 0.01 wt% and 50 wt%	30	21% amélioration pour Au/water; Détérioration pour SiO_2/EG-water
Al_2O_3/water; 0.1–4 vol%	20–50	Détérioration
Al_2O_3/water;0.001–0.025 g/L	/	inchangée
Al_2O_3/water;	38	64% amélioration
SiO_2/water; 0.5 vol%	15–3000	inchangée
Al_2O_3/water; 1.25 wt%	10–50	40% amélioration
Al_2O_3/water; 0.5–4 vol%	10–100	Détérioration
Al_2O_3/water, ZrO2/water,	110–250	Détérioration
SiO2/water; 0.001–0.1 vol%	20–40	
CuO/water; 0.1–2 wt%	30	25% amélioration pour 100kPa, 150% Amélioration pour 7.4kPa
Al_2O_3/water, 0.026–1.02 g/L; Al2O3/ethanol,0.001–10 g/L	45	amélioration
ZrO_2/water; 0.005–0.15 vol%	20–25	Amélioration pour les faibles concentrations ; Détérioration pour les fortes concentrations
SiO_2–CuO/water; 0.057–0.57 vol%	35–50	Faible amélioration
Al_2O_3/water,	20–30	30% amélioration
SnO2/water; 0.3–2 wt% and 0.5–3 wt%	55	20% amélioration
CNTs/water; 10^{-4}–0.05 vol%	10–20	38.2% détérioration
Cu/water; 0.25–1 wt%	10	30% amélioration
TiO_2/R141b	21	Détérioration
CNT/water; 0.5–4 wt%	15	60% amélioration pour 100kPa; 130% Amélioration pour 7.4kPa
Cu/water with or without SDS	10	Détérioration
Al_2O_3–CuO–diamond/water; ≤ 1 g/L	139–143–86 respectivement	Détérioration
TiO_2/water; 0.00005–0.01 vol%	21	15% amélioration (Cu plate) Détérioration(Al plate)
Diamond–Al_2O_3–ZnO/water; 0.01–0.1 vol%	4–50–70 respectivement	inchangée
TiO_2/water, Au/water, Al_2O_3/water; 0.0003–0.01 vol%	15–30 80–100	50% détérioration
Al_2O_3/water; 0.8–1.4 wt%	20–30	25% amélioration
γ-Fe_2O_3/water; 0.1 wt%	10	Deterioration
TiO_2/water; 0.01–1 wt%	110–220	Détérioration
α-Al_2O_3/water; 0.001–0.1 vol%	10	200% amélioration pour une surface lisse, Inchangé pour une surface rugueuse
Al_2O_3/water; 0.5–2 vol%	< 50	Amélioration pour une surface rugueuse ; 30% détérioration pour une surface lisse
CuO/EG-water; 0.1–0.5 wt%	40	55% amélioration
SiO_2/water; 0.5–2.5 wt%	30	27.3% amélioration (7.4kPa)
α-Al_2O_3/water; 0.001–0.1 vol%	20–150	amélioration pour une surface lisse ; inchangée pour une surface rugueuse
Fe_3O_4/EG-water; 0.01–0.1 vol%	< 50	Détérioration
TiO_2/water; 0.000094–0.047 vol%	21	Détérioration puis amélioration
TiO_2/water; 0.0011 wt%	25	amélioration
Al_2O_3/water; 0.01–0.5 vol%	40–50	Amelioration pour 0.01 vol%, Détérioration avec la diminution du concentration
Al_2O_3/water; 10^{-5}–0.1 vol%	45	
ZnO-EG; 0.5–3.75 vol%	30–50	22% amélioration pour 1.6 vol%
ZnO; 0.01 vol%	/	amélioration

Le Tableau II.4 représente un résumé des investigations expérimentales sur le coefficient de transfert de chaleur d'un écoulement en ébullition des nonofluides [121-131].

Tableau II**.4. Résumé des investigations expérimentales sur le HTC des écoulements en ébullition des nanofluides**

Source	Paramètres de l'écoulement p(kPa)/d(mm)/ L(mm) /G(kg m^{-2}s^{-1})/q(kW m^{-2})	Concentration du nanofluide	Dimension des particules (nm)	Transfert de chaleur
Faukner et al. [120]	101/0.923–1.714/10/ */ 100–2750	Al_2O_3, Al-N/eau; 0.25–0.5 wt%	*	Deterioration et amelioration
Peng et al. [121]	78.25/8.12/1400/100–200/3.08–6.16	CuO/R113; 0–0.5 wt%	40	29.7% amélioration
Kim et al. [122]	101/5.53/100/1500–2500/ 100–7500	Al_2O_3/water, ZnO/water, diamond/water; 0.001–0.1 vol%	40–165.4	Amelioration (dans 20%).
Boudouh et al. [123]	*/0.8/160/167–616/*	Cu/water;0.00056–0.0056 vol%	35	Amélioration avec l'augmentation du concentration
Henderson etal. [124]	835/7.9/2000/125–390/ 5.8–16.2; 336/7.9/2000/ 125–390/ 0.7–3.1	SiO_2/R134a; 0.05–0.5 vol%. CuO/R134a/POE;0.02–0.08 vol%	200–300 pour SiO_2. 30 pour CuO	55% deterioration pour SiO_2/R134a; > 100% amélioration pour CuO /R134a/POE
Xu and Xu [125]	101/0.143/7.5/171–401/ 0–1000	Al_2O_3/water; 0.2 wt%	40	17% amélioration
Abedini et al.[126]	101/10/1000/137–303/ 51–102	TiO_2/water; 0.1–2.5 vol%	20	Amélioration avec l'augmentation du concentration
Chehade et al.[127]	101/0.8/160/87–653/3–6	Ag/water; 0.000237–0.000475 vol%	35	132%–162% amélioration
Rana et al.[128,129]	101/21.8/500/405–710/ 100–550	ZnO/water; 0.001–0.01 vol%	40	Amélioration avec l'augmentation du concentration
Sun and Yang [130]	101/10/1400/120–330/*	Cu/R141b, Al/R141b, Al_2O_3/R141b, CuO/R141b, 0.1–0.3 wt%	40	49% amélioration pour Cu/R141b
Sarafraz and Hormozi [131]	*/30/140/353–1059/0–190	CuO/water; 0.5–1.5 vol%	50	Détérioration avec concentration

II.3.1. Modélisation de l'ébullition des nanofluides par RNA

La technique des réseaux de neurones artificiels (ANN) est largement utilisée pour résoudre les problèmes de transfert de chaleur en ébullition [68, 69, 70, 132], Cette technique est également utile dans la modélisation du transfert de chaleur par ébullition en écoulement de nanofluides [133-135], ANN est utilisé aussi pour divers domaines d'application [136-139].

ANN a été utilisé pour la prédiction du HTC l'écoulement en ébullition des nanofluides Al_2O_3 et TiO_2 dans un tube horizontal [67], prédiction du coefficient de transfert de chaleur en ébullition en piscine pour divers nano-réfrigérants [113].

La figure II.7 représente l'évolution des articles publiés pour la prédiction du coefficient de transfert de chaleur des écoulements en ébullition des nanofluides par les réseaux de neurones artificielle dans la dernière décennie (Google Scholar).

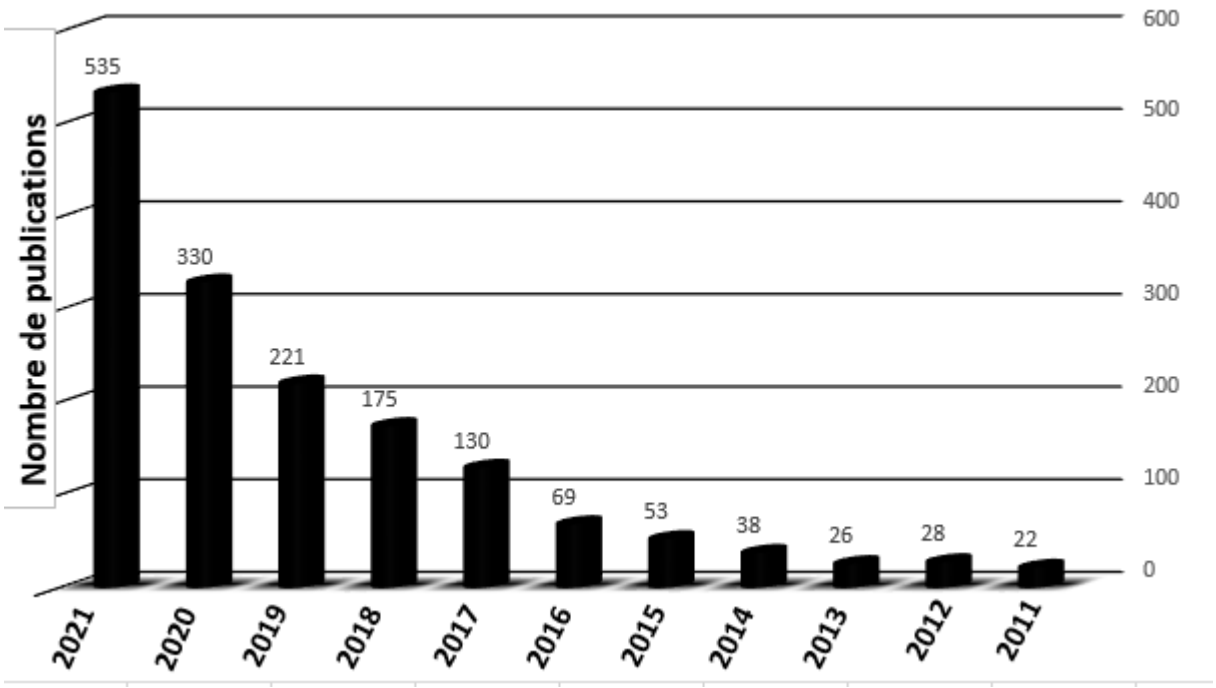


Figure II**.7. Evolution des articles publiés pour la prédiction du coefficient de transfert de chaleur pour des écoulements en ébullition des nanofluides par RNA**

II.3.1. Modélisation de l'ébullition des nanofluides par SVM

Les machines à vecteurs de support (SVM) sont l'une des techniques d'intelligence artificielle peut fournir des outils utiles pour la modélisation et la corrélation des problèmes de transfert de chaleur pratiques, cette technique est utilisée pour la prédiction de la conductivité thermique d'Al_2O_3/EG nanofluide [140], pour la simulation numérique de l'ébullition d'un écoulement sous-refroidi [141], modélisation du coefficient de transfert de chaleur d'un réacteur de recherche nucléaire [142], prédiction de la conductivité thermique de Al_2O_3/eau nanofluide [143], cette technique est également utilisée pour divers domaines d'application [82, 83, 144].

La figure II.8 représente l'évolution des articles publiés pour la prédiction du coefficient de transfert de chaleur des écoulements en ébullition des nanofluides par la machine à vecteurs de support (Google Scholar).

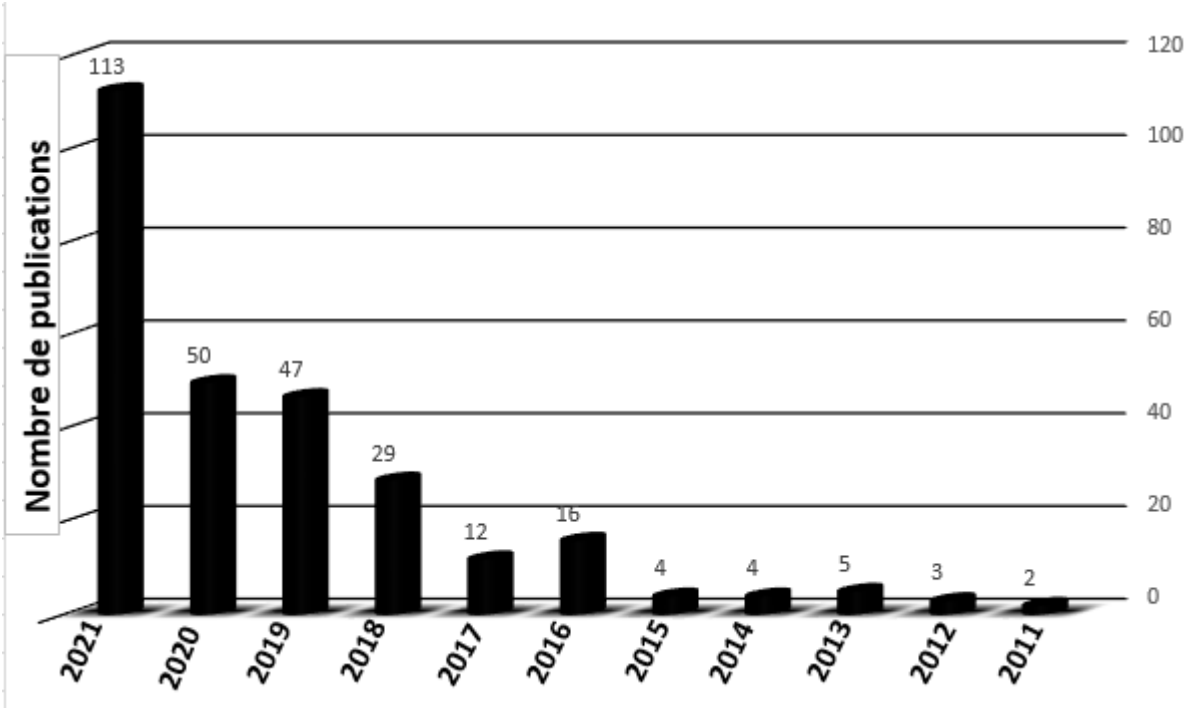


Figure II.8. Evolution des articles publiés pour la prédiction du coefficient de transfert de chaleur pour des écoulements en ébullition des nanofluides par SVM

II.4. Conclusion

Dans ce chapitre nous avons présenté une recherche bibliographique sur les corrélations du coefficient de transfert de chaleur des écoulements en ébullition des fluides et des nanofluides, nous allons présenter une recherche bibliographique sur l'application des méthodes d'intelligence artificielle (RNA, SVM) pour la modélisation des écoulements en ébullition des fluides et des nanofluides.

Chapitre **III**

Techniques d'intelligence artificielle

CHAPITRE III: Techniques d'intelligence artificielle

III.1. Introduction

Le cerveau humain a une fantastique puissance de traitement de l'information si l'on considère ses capacités à prendre en charge certaines tâches nécessaires pour obtenir un comportement intelligent. La nature de l'intelligence a longtemps été un sujet difficile et controverse. D'une certaine manière, chacun a une idée assez vague de ce qu'est l'intelligence : la capacité à observer, à comprendre, à se souvenir, à résoudre des problèmes, à apprendre, à créer,…

Les techniques de l'intelligence artificielle telles que la logique floue, les algorithmes génétiques et les réseaux de neurones artificiels (RNA), les vecteurs à support machine ont été largement utilisées dans le domaine de modélisation de transfert de chaleur en ébullition **(**voir figure III.1).

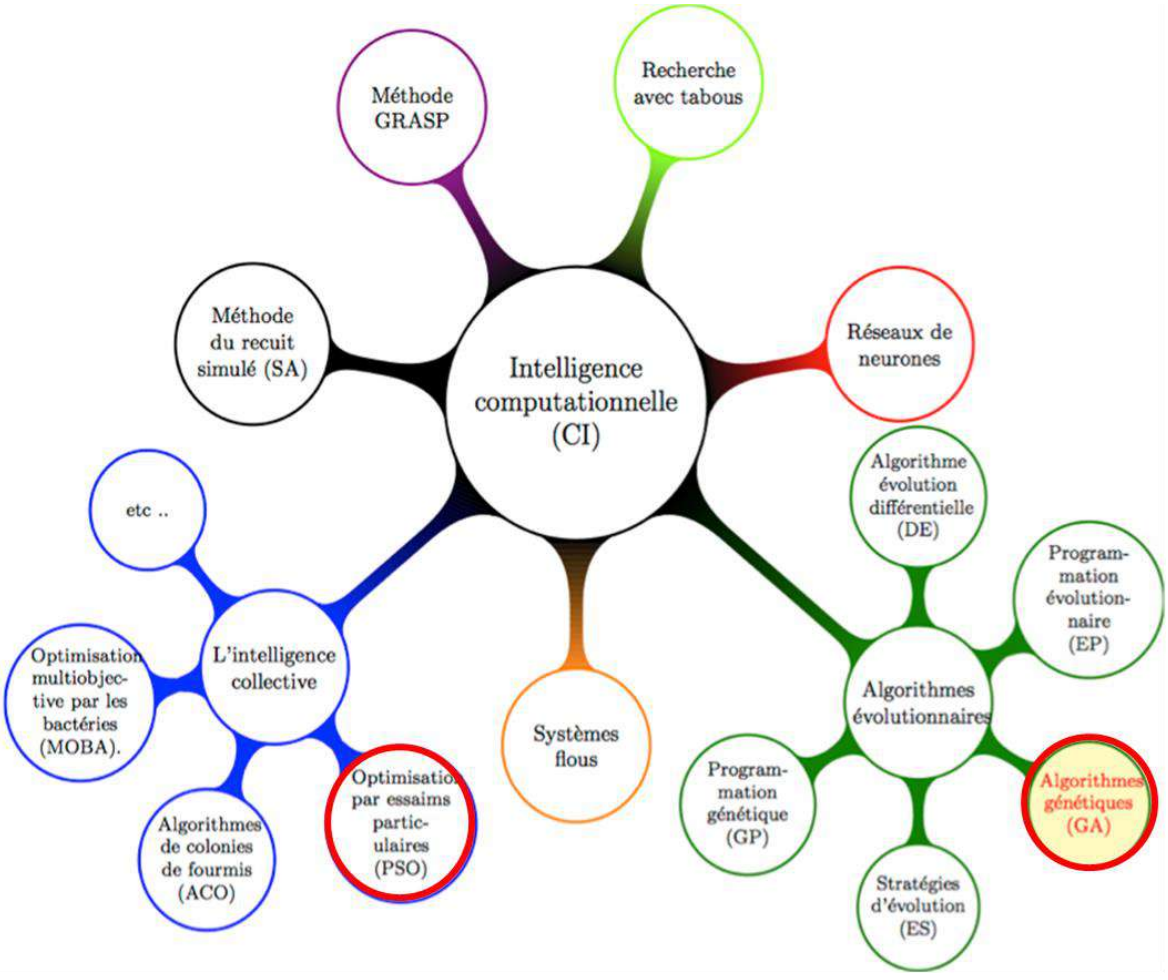


Figure III.1. Les techniques d'intelligence artificielles utilisées pour la modélisation du transfert de chaleur en ébullition [145]

L'objectif de ce chapitre est de présenter la technique de réseaux de neurones artificiels et la technique des vecteurs à support machine. Ces techniques d'intelligence artificielles sont utilisées dans ce travaille pour modéliser le transfert de chaleur des écoulements en ébullition des fluides et des nanofluides.

III.2. Les réseaux de neurones artificiels

L'élément de base du système nerveux central est le neurone. Le cerveau se compose d'environ mille milliards de neurones, avec 1000 à 10000 synapses (connexions) par neurone. Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. [146]

Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. Celles-ci sont parfois si nombreuses que l'on parle alors de chevelure dendritique ou d'arborisation dendritique. C'est par les dendrites que l'information est acheminée de l'extérieur vers lesoma (corps du neurone). L'information est traitée alors par le corps cellulaire. Si le potentiel d'action dépasse un certain seuil, le corps cellulaire répond par un stimulus.

Le signal transmis par le neurone chemine ensuite le long de l'axone (unique) pour être transmis aux autres neurones. La transmission entre deux neurones n'est pas directe.

En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée synapse. [147]

III.2.1. Le neurone

Avant de commencer à énumérer les types de neurones, nous allons expliquer très brièvement les bases biologiques dont ils sont originaires [147].

III.2.2. Bases biologiques

Le neurone est le processeur élémentaire du cerveau. Chaque neurone traite l'information qui lui parvient localement, puis transmet aux autres neurones qui lui sont connectés l'information qu'il a traitée. Ces cellules peuvent apprendre en changeant l'intensité de leurs connexions avec d'autres cellules ou détruire ou même créer de nouvelles connexions. Elles peuvent aussi changer leur(s) règle(s) de traitement de l'information [147].

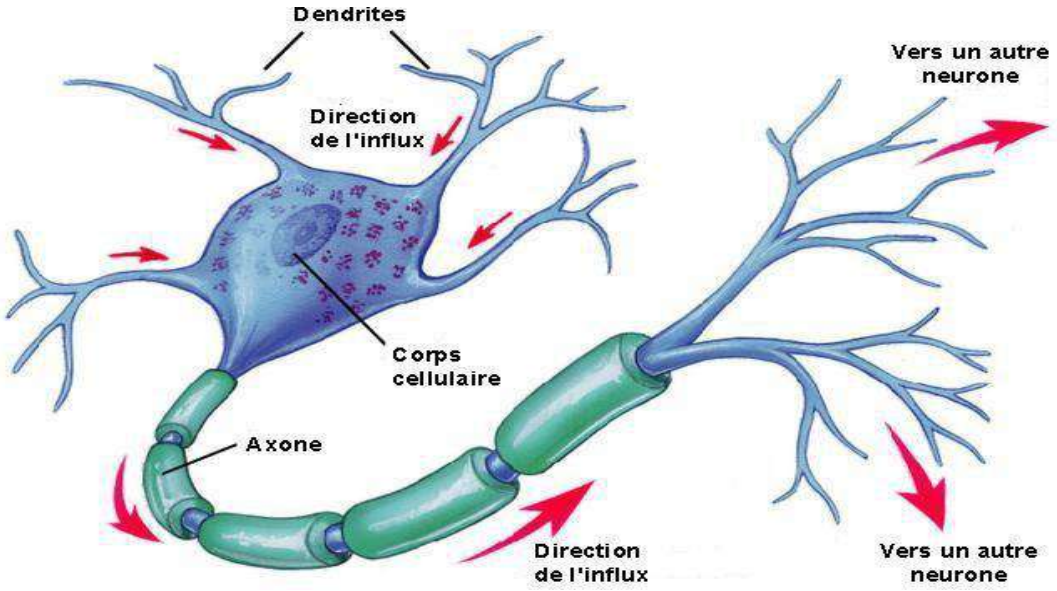


Figure III.2. Neurone biologique avec son arborisation dendritique [147]

Ce processus de changement est appelé apprentissage et joue un rôle fondamental dans le comportement du neurone [148]. La figure suivante décrit un neurone avec son arborisation dendritique.

D'après la figure, vous pouvez constater que le neurone est composé des parties suivantes : corps cellulaire, dendrites (récepteurs principaux du neurone), axone (fibre nerveuse de transport pour les signaux émis par le neurone), synapse (connexion entre la dendrite et l'axone de deux neurones).

III.2.3. Le neurone artificielle

Le neurone formel représente la brique de base des RNA, c'est un automate dont le modèle s'inspire de celui d'un neurone biologique. Les premiers travaux datent de 1943 par *MM. Mac Culloch* et *Pitts.* Ils présentent un modèle assez simple pour le neurone et explorent les possibilités de ce modèle pour concevoir tous les réseaux de neurones [149].

Cette modélisation consiste à mettre en œuvre le système sous un aspect non pas biologique mais artificiel, cela suppose que d'après le principe biologique qu'on aura une correspondance pour chaque élément composant le neurone biologique, donc une modélisation pour chacun d'entre eux [150,151].

On pourra résumer cette modélisation par le tableau ci-dessous (III.1), qui nous permettra de voir clairement la transition entre le neurone biologique et le neurone formel.

Tableau III.1 Transition entre le neurone biologique et le neurone formel

Neurone biologique	Neurone artificiel
Synapse	Poids de connexion
Axone	Signal d'entrée
Dendrite	Signal de sortie
Somma	Fonction d'activation

Nous pouvons définir un neurone par les trois éléments suivants [149] : la fonction d'entrée totale qui définit le pré-traitement effectué sur les entrées, la fonction d'activation du neurone qui définit son état interne en fonction de son entrée totale, la fonction de sortie qui calcule la sortie du neurone en fonction de son état d'activation.

Nous adopterons les notations suivantes :

u_i : Entrées du neurone *(i=1..n);*

w_i : Coefficient de pondération de l'entrée *;*

$h(\bullet)$: Fonction d'entrée totale ;

$f(\bullet)$: Fonction d'activation ;

$g(\bullet)$: Fonction de sortie ;

$E=h(u_1,..,u_n)$: Entrée totale ou degré d'activation ;

$A=f(E)$: Etat du neurone ;

$S=g(A)$: Sortie ;

La figure II.3 montre la représentation graphique du modèle général d'un neurone.

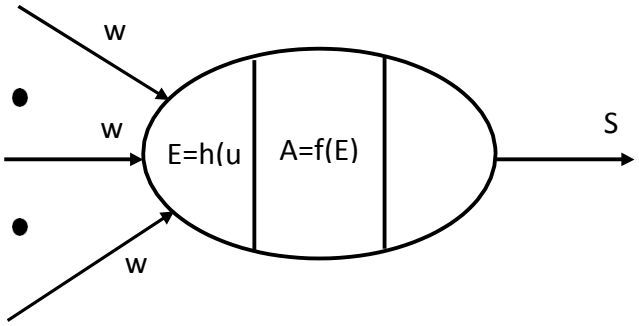


Figure III.3. Modèle générale d'un neurone [151]

Les entrées et les sorties peuvent être des grandeurs réelles ou binaires. La nature des différentes entrées, sorties et fonctions est explicitées ci-dessous.

- Une combinaison booléenne des entrées ;
- Une combinaison linéaire des entrées.

$$h(u_1,...,u_n) = b + \sum_{i=1}^{n} w_i u_i \quad \text{ou} \quad h(u_1,...,u_n) = b + w^T u \tag{III.1}$$

La distance entre les vecteurs formés par les valeurs d'entrée et les coefficients de pondération. Cette fonction est utilisée avec la fonction d'activation à base radiale. Dans ce cas les W_i représentent plutôt des points de l'espace d'entrée aux des coefficients de pondération.

$$h(u_1,...,u_n) = b\sqrt{\sum_{i=1}^{n}(w_i - u_i)^2} \quad \text{ou} \qquad h(u_1,...,u_n) = b\,\|w - u\| \tag{III.2}$$

Ces deux derniers cas sont les plus fréquents.
La fonction d'activation *f (•)* prend généralement les formes suivantes [151, 152]:

- Une fonction binaire à seuil (figure III.4.a) ;
- Une fonction linéaire à seuil ou seuils multiples (figure III.4.b, figure III.4.c et figure III.4.d ;
- Une fonction sigmoïde (figure III.4.e) ;

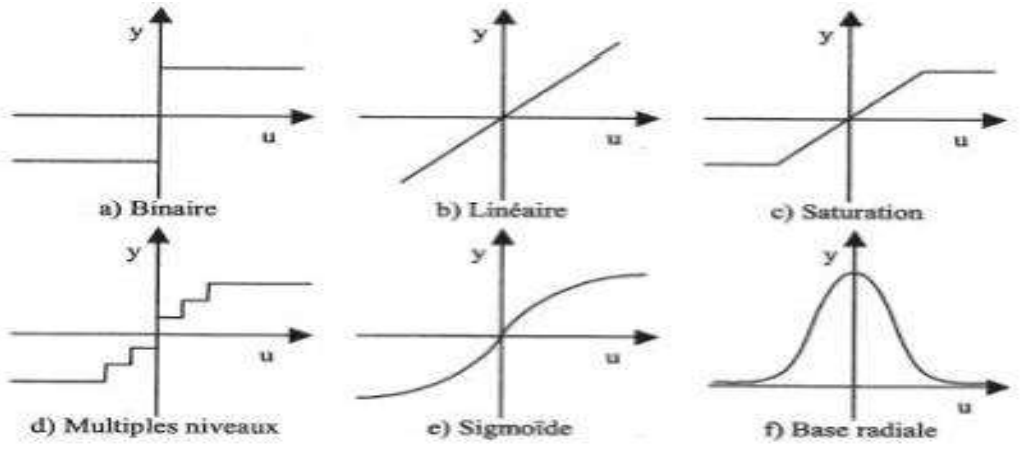


Figure III.4. Fonctions de sortie des neurones [152]

Une fonction stochastique.

$$f(x) = \begin{cases} 1 & \text{Avec probabilité } (1+e^{-kx})^{-1} \\ 0 & \text{Autrement} \end{cases} \quad \text{(III.3)}$$

Une fonction compétitive : avec cette fonction, seule la sortie du neurone dont l'entrée totale est la plus grande est activée et les autres sont forcées à zéro, d'où le terme de compétition ou concurrence entre plusieurs neurones. Chacune des fonctions d'activation est adaptée à certaines applications. Par exemple, la fonction binaire ou les fonctions de type «compétitive» sont bien adaptées pour l'organisation et la distribution classification des entrées (par exemple, le maillage automatique). Les fonctions linéaires, sigmoïdes, à base radiale et plus généralement des fonctions continues et dérivables sont appropriées pour l'approximation des fonctions continues (voir la partie sur l'apprentissage ou les références [151, 152] pour plus de détails sur cette propriété). La fonction de sortie *g (•)* est souvent considérée comme la fonction identité. Par la suite, nous confondrons toujours activation et sortie du neurone : *S=A=f (E).*

III.2.4. Architecture des réseaux de neurones

L'architecture d'un réseau de neurones est fonction du nombre de couches de ce dernier et surtout de la structure des connexions entre neurones. Il existe plusieurs types d'architectures, on peut citer : réseaux monocouche, réseaux multicouches, réseaux à connexions locales, réseaux à connexions complètes [152].

III.2.5. Connexions des réseaux de neurones

La nature des connexions définit la manière dont sont interconnectés les neurones et le sens de transfert d'information dans le réseau, où on distingue : les Connexions Directes, celles dirigées d'une couche d'indice inférieur vers une couche d'indice supérieur (figure III. 5). Les Connexions Récurrentes dont les sorties de neurones d'une couche sont connectées aux entrées d'une couche d'indice inférieur (figure III.6) [152].

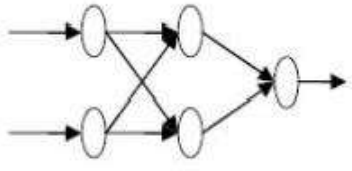


Figure III.5. Connexions directes

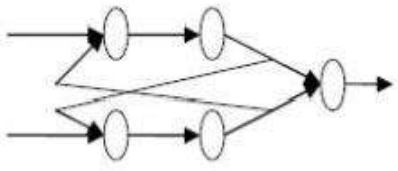


Figure III.6. Connexions récurrentes

Par ailleurs entre deux couches, les connexions peuvent être partielles ou totales comme le montre les figures III.7 et III.8. L'utilisation de connexions partielles permet de regrouper certaines zones du réseau pour effectuer une fonction spécifique.

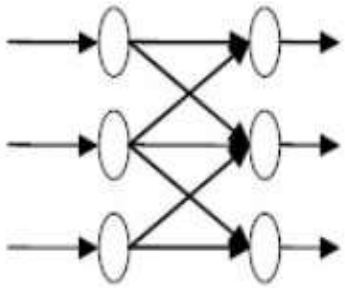


Figure III.7. Connexions partielles

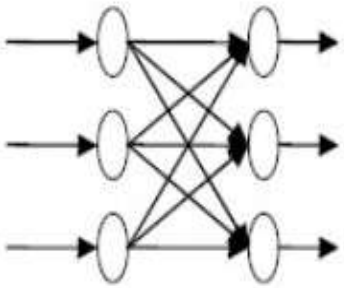


Figure III.8. Connexions totales

On peut avoir éventuellement en plus des connexions citées précédemment des connexions inter-couches (interconnexions entre neurones de couches voisines), des connexions intra-couches (connexions entre neurones d'une même couche) et l'auto-connexion (un neurone avec lui-même) [152].

III.2.6. Réseaux de neurones multicouches

Un réseau multicouche n'est rien d'autre qu'un assemblage de couches les unes aux autres, de la gauche vers la droite, en prenant les sorties d'une couche et en les injectant comme les entrées de la couche suivante. Ce type de réseau comme le montre la figure III.9, est organisée en couches de neurones. Généralement, il n'y a pas de connexions entre neurones d'une même couche, et les connexions ne se font qu'avec ceux des couches en aval.

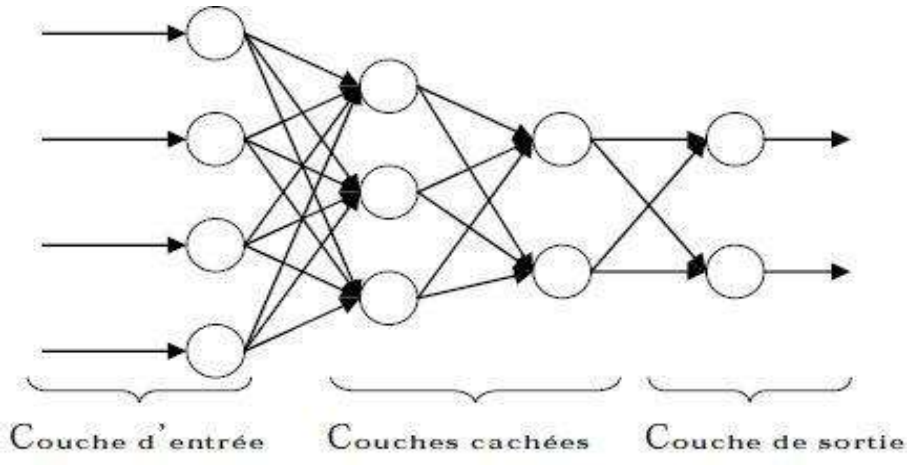


Figure III.9. Réseau de neurones multicouches [152]

III.2.7. Apprentissage des réseaux de neurones

La plus fondamentale des propriétés propres au réseau de neurones est sa capacité d'apprendre de son environnement et d'améliorer sa performance à travers un processus d'apprentissage. On définit l'apprentissage comme étant un changement opéré dans la mémoire du réseau en affectant les valeurs des poids synaptiques qui relient les neurones entre eux, afin d'adapter le traitement effectué par le réseau à une tâche particulière. De ce fait l'apprentissage a pour objectif l'amélioration des performances futures du réseau, sur la base d'une connaissance acquise au fur et à mesure des expériences passées.

On distingue trois familles d'apprentissage différentes en fonction de la nature des informationsdisponibles et du but recherché

Apprentissage supervisé pour lequel il est nécessaire de disposer d'un ensemble de couples de données (entrées du réseau ; sorties désirées correspondantes).

Apprentissage semi-supervisé ou **par renforcement** pour lequel seule une mesure d'erreur qualitative est disponible.

Apprentissage non supervisé pour lequel il n'y a pas de réponse désirée.

Il a été démontré que moyennant le choix d'une architecture appropriée (nombre de neurones cachés), les réseaux multicouches sont capables d'approcher n'importe quelle fonction. Une autre propriété fondamentale de l'apprentissage concerne la capacité de généralisation de ces réseaux [151, 152].

III.2.8. Algorithme d'apprentissage

L'apprentissage se traduit, dans la plupart des architectures, par une modification de l'efficacité synaptique qui s'effectue en changeant les valeurs des poids qui relient les neurones d'une couche à l'autre.

Soit w_{ij} le poids reliant le $j^{éme}$ neurone d'une couche au $i^{éme}$ neurone de la couche suivante. A l'instant t un changement $\Delta w_{ij}(t)$ s'exprime en fonction de $w_{ij}(t+1)$ et $w_{ij}(t)$ qui sont respectivement les nouvelle et ancienne valeurs du poids w_{ij} par l'équation :

$$\Delta w_{ij}(t) = w_{ij}(t+1) - w_{ij}(t) \qquad \text{(III.4)}$$

L'ensemble de règles permettant la réalisation d'un tel processus d'adaptation des poids constitue ce qu'on appelle l'algorithme d'apprentissage du réseau. Il existe plusieurs algorithmes d'apprentissage des réseaux de neurones. Dans le cadre de notre travail, on utilisel'algorithme de rétropropagation du gradient [152].

III.2.9. Rétropropagation du gradient

De nos jours, les réseaux multicouches et la rétropropagation de gradient reste le modèle le plus étudié et le plus efficace pour réaliser l'adaptation des réseaux multicouches.

L'algorithme de rétropropagation (backpropagation) a été développé en particulier par Rumelhart et Parken et le Cun en 1985. Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables. Cet algorithme repose sur la minimisation de l'erreur quadratique J entre les sorties calculées (réelle) et celles souhaitées (désirée). Le terme rétropropagation du gradient provient du fait que l'erreur calculée en sortie est transmise en sens inverse vers l'entrée [152].

$$j = \frac{1}{2}e^2 = \frac{1}{2}(y_d - y)^2 \qquad \text{(III.5)}$$

e : est l'écart entre la sortie réelle y et la sortie désirée y_d. La théorie de rétropropagation comporte deux phases:

Une propagation dans le sens direct des signaux de la couche d'entrée, couche par couche, jusqu'à atteindre la couche de sotie qui délivre les signaux de sortie du réseau.

Une rétropropagation de l'erreur, qui se propage dans le sens inverse, de la couche de sortie jusqu'à atteindre la couche d'entrée qui sera utilisée pour l'ajustement des paramètres du réseau.

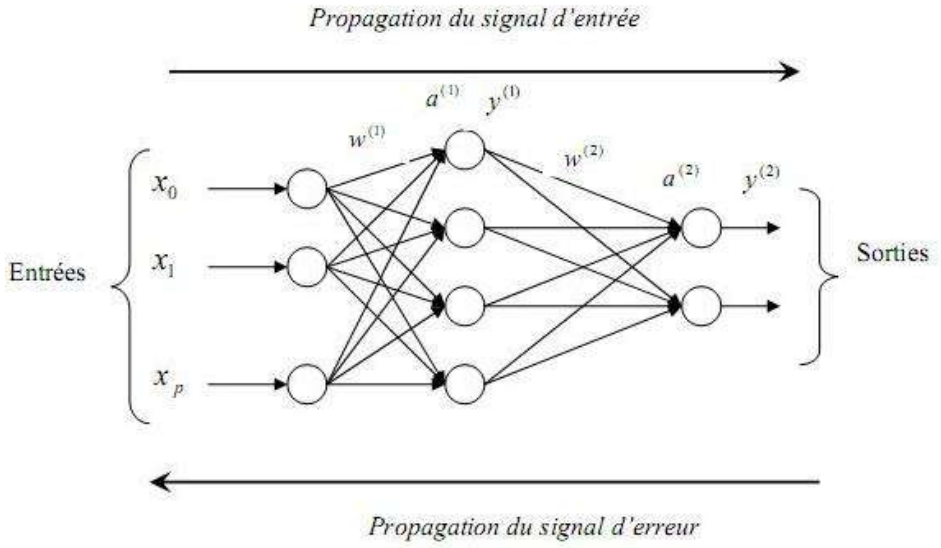


Figure III.10. Flux des signaux de la rétropropagation

Soit le réseau multicouche de la figure III.9.

$w^{(L)}$: le vecteur des poids synaptiques d'un neurone appartenant à la couche L ;

$a^{(L)}$: le vecteur activités des neurones de la couche L ;

$y^{(L)}$: le vecteur des sorties de la couche L ;

$f(.)$: la fonction d'activation d'un neurone.

L'algorithme d'apprentissage est donné par les étapes suivantes :

- Initialiser les poids : attribuer à chaque poids une valeur aléatoire entre -1 et +1 ;
- Présenter un exemple au réseau : on présente un exemple x_p en entrée et une valeur désirée en sortie ;
- Propager les signaux d'activation des entrées vers les sorties : on calcule les sorties de la première couche qui deviennent les entrées de la couche suivante puis on fait de même jusqu'àla dernière couche.

L'activité du neurone j de la couche L pendant l'itération n

$$a_j^{(L)}(n) = \sum_{i=0}^{P} W_{ij}^{(L)}(n).y_i^{(L-1)}(n) \quad \text{(III.6)}$$

w_{ij} : le poids synaptique d'un neurone j appartenant à la couche (L) relié à un neurone i appartenant à la couche (L-1).

Les sorties des réseaux de la n^{éme} itération sont notées : $o_j(n) = y_i^{(L)}$ (III.7)

Comparer avec les sorties désirées et rétropropager l'erreur des couches de sortie. Le calcul des gradients :

- Pour un neurone de la couche de sortie : $\delta_i(n) = e_i(n).f'(a_i(n))$ (III.8)
- Pour un neurone caché : $\delta_i(n) = f'(a_i(n)).\sum_k \delta_k(n).w_{kj}(n)$ (III.9)

Une des fonctions d'activation la plus utilisée généralement est la fonction sigmoïde définiecomme suit :

$$f(x) = \frac{1}{1+\exp(-x)} \quad \text{(III.10)}$$

Ou : $f'(x) = f(x).[1-f(x)]$ (III.11)

$$f'(a_j(n)) = f(a_j(n)).\left[1-f(a_j(n))\right] = y_i(n).[1-y_i(n)] \quad \text{(III.12)}$$

En utilisant les propriétés de la fonction sigmoïde, les équations (3.21) et (3.22) deviennent :

Pour un neurone de la couche de sortie :

$$\delta_j(n) = \left[d_j(n) - o_j(n)\right].o_j(n)\left[1 - o_j(n)\right] \quad \text{(III.13)}$$

Pour un neurone caché

$$\delta_j(n) = o_j(n)\left[1 - o_j(n)\right].\sum_k \delta_k(n) W_{jk}(n) \quad \text{(III.14)}$$

-Modifier les poids en appliquant la loi généralisée suivante :

$$\Delta w_{ji}^{(L)}(n+1) = \Delta w_{ji}^{(L)}(n) + \eta.\delta_j^{(L)}.y_i^{(L-1)}(n) \quad \text{(III.15)}$$

$\Delta w_{ji}^{(L)}(n+1)$: Le poids synaptique reliant le neurone *i* de la couche *(L-1)* au neurone *j* de la couche *(L)* à l'itération *n+1*.

$\Delta w_{ji}^{(L)}(n)$: Le poids synaptique reliant le neurone *i* de la couche *(L-1)* au neurone *j* de la couche *(L)* à l'itération *n*.

η : Le pas d'apprentissage.

$\delta_j^{(L)}$: Le gradient local du neurone *j* de la couche *(L).*

$y_i^{(L-1)}$ *:* La sortie du neurone *i* appartenant à la couche *(L-1)* à l'itération *n.*

Le critère d'arrêt : plusieurs critères peuvent être utilisés avec l'algorithme de rétropropagation des erreurs. Le plus commun consiste à fixer un nombre maximum de périodes d'entraînement, ce qui fixe effectivement une limite supérieure sur la durée de l'apprentissage.

Ce critère est important car la rétropropagation des erreurs n'offre aucune garantie quant à la convergence de l'algorithme. Il peut arriver, que le processus d'optimisation reste pris dans un minimum local. Sans un tel critère, l'algorithme représenté par la figure III.11 pourrait ne jamais se terminer.

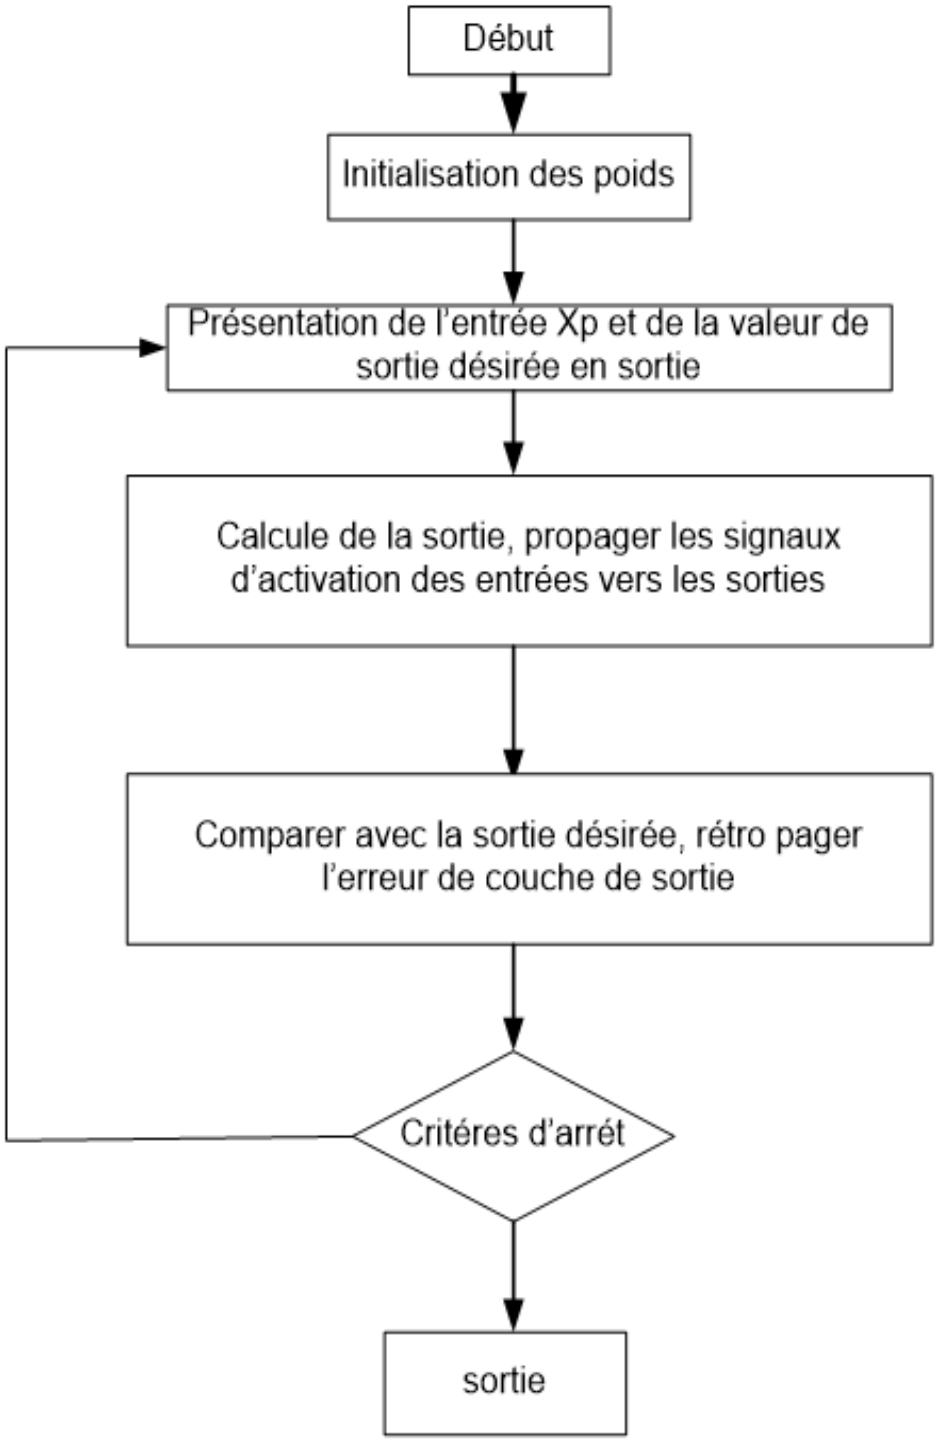


Figure III.11. Algorithme de la rétropropagation de l'erreur [152].

III.3. Machine à vecteurs support

Les machines à vecteur support se situent sur l'axe de développement de la recherche humaine des techniques d'apprentissage. Les SVMs sont une classe de techniques d'apprentissage introduite par Vladimir Vapnik au début des années 90 [153, 154], elles reposent sur une théorie mathématique solide à l'inverse des méthodes de réseaux de neurones. Elles ont été développées au sens inverse du développement des réseaux de neurones : ces derniers ont suivi un chemin heuristique de l'application et l'expérimentation vers la théorie ; alors que les SVMs sont venues de la théorie du son vers l'application.

Les SVMs sont dans leur origine utilisées pour la classification binaire et la régression. Aujourd'hui, elles sont utilisées dans différents domaines de recherche et d'ingénierie tel que le diagnostic médical, le marketing, la biologie, la reconnaissance de caractères manuscrits et de visages humains...

III.3.1. Apprentissage des machines à vecteurs support

La théorie d'apprentissage statistique étudie les propriétés mathématiques des machines d'apprentissage [154]. Ces propriétés représentent les propriétés de la classe de fonctions ou modèles que peut implémenter la machine. L'apprentissage statistique utilise un nombre limité d'entrées (appelées exemples) d'un système avec les valeurs de leurs sorties pour apprendre une fonction qui décrit la relation fonctionnelle existante, mais non connue, entre les entrées et les sorties du système.

On suppose premièrement que les exemples d'apprentissage, appelés aussi exemples d'entrainement, sont générés selon une certaine probabilité inconnue (mais fixe) c'est-à-dire indépendants et identiquement distribués (iid). C'est une supposition standard dans la théorie d'apprentissage. Les exemples sont de dimension m ($m \in \Re^m$) et dans le cas d'apprentissage supervisé, accompagnés d'étiquettes caractérisant leurs types ou classes d'appartenance. Si ces étiquettes sont dénombrables, on parle de classification sinon on parle de régression.

Dans le cas d'une classification binaire cette étiquette est soit +1 ou -1. L'ensemble des exemples et leurs étiquettes correspondantes est appelés ensemble d'apprentissage [154].

Une machine efficace d'apprentissage est une machine qui apprend de l'ensemble d'entrainement une fonction qui minimise les erreurs de classification sur l'ensemble lui-même.

Soit $D = \{(x_1, y_1), ...(x_n, y_n)\}$ l'ensemble des exemples d'entrainement avec $x_i \in \Re^m$ et $y = \pm 1$, et soit $f(x)$ la fonction apprise par la machine d'apprentissage. On parle le risque empirique $R_{emp}[f]$ le taux d'erreurs effectuées par la fonction f sur l'ensemble d'entrainement D.

$$R_{emp} = \frac{1}{n}\sum_{i=1}^{n} L(y_i, f(x_i)) \qquad \text{(III.16)}$$

Avec L=1 si $y_i = f(x_i)$, sinon L=0.

Puisque l'ensemble D ne représente qu'une simple partie de tout l'espace d'exemples, la fonction apprise f, qui minimise le risque empirique, peut se comporter mal avec les nouveaux exemples non vus à l'entrainement. C'est un phénomène très connu en apprentissage automatique appelé le sur-apprentissage ou apprentissage par cœur. Pour garantir que f, prenne en charge même les exemples non jamais vus, il faut contrôler sa capacité de généralisation mesurée souvent sur un autre ensemble d'exemples appelé ensemble de test réservé uniquement pour tester la machine apprise.

La fonction f recherchée doit donc minimiser les erreurs de classification sur les deux ensembles : d'entrainement et de test.

Trouver la fonction optimale f revient toujours à un problème d'optimisation, ce qui explique la forte relation entre l'apprentissage et l'optimisation. Avant de rechercher la fonction f , il faut définir son type puis rechercher ses paramètres.

Dans le cas des machines à vecteur support, la fonction recherchée est de forme linéaire. Les SVMs sont, donc, des systèmes d'apprentissage qui utilisent un espace d'hypothèses de fonctions linéaires dans un espace de caractéristique à haute dimension. Cette stratégie d'apprentissage introduite par Vapnik et ses co-auteurs [155] est une méthode très puissante. Elle a pu, en quelques années depuis sa proposition, conquérir la plupart des autres systèmes d'apprentissage dans une grande variété de domaines d'application.

III.4. Conclusion

L'intelligence artificielle est un outil utilisé pour modéliser les phénomènes complexe de transfert de chaleur en ébullition. Dans la dernière décennie un nombre important d'études basée sur les différent technique d'intelligence artificielle pour la modélisation du transfert de chaleur par ébullition. Dans ce chapitre nous allons présenter les deux techniques d'intelligence artificielle (RNA, SVM) qui seront appliqué dans le chapitre quatre pour prédire le coefficient de transfert de

chaleur pour un écoulement en ébullition dans un tube incliné, modélisation de l'ébullition en film, et la modélisation de l'ébullition des nanofluides dans un tube horizontale.

Chapitre *IV*

Contribution à la modélisation de l'ébullition par les techniques d'intelligence artificielle

IV.1. Introduction

L'intelligence artificielle est un outil de modélisation des phénomènes complexes de transfert de chaleur, les techniques d'intelligence artificielles les plus utilisées sont les réseaux de neurones artificiels RNA et les machines à vecteurs support SVM.

Dans ce chapitre on présente les différentes contributions qui ont été réalisée dans ce travail dans le but de modélisation de l'ébullition.

La première contribution consiste à développer un modèle de prédiction de HTC pour un écoulement en ébullition dans un tube incliné, le but de la deuxième contribution est de modéliser l'ébullition en film.

Dans la troisième contribution nous avons développé un modèle neuronale de prédiction du coefficient de transfert de chaleur pour les écoulements en ébullitions des nanofluides dans un tube horizontale.

La quatrième contribution à appliquer la technique de machine à vecteurs support pour prédire le HTC pour les écoulements en ébullition des nanofluides Al_2O_3/Eau et TiO_2/Eau dans un tube horizontale.

IV.2. Modélisation de l'ébullition dans un tube incliné

IV.2.1. Introduction

L'intelligence artificielle est un outil utilisé pour modéliser les phénomènes complexe de transfert de chaleur, les réseaux de neurones artificiels sont l'une des techniques d'intelligence artificielle pouvant fournir des outils utiles pour modéliser et corréler les problèmes pratiques de transfert de chaleur.

Les grands avantages des réseaux de neurones artificiels sont leur capacité à apprendre, à généraliser ou à extraire automatiquement des règles à partir de données complexes.

Ce travail consiste en l'application du réseau de neurones artificiels pour développer un modèle de prédiction du coefficient de transfert de chaleur pour l'ébullition de l'eau dans un canal incliné en fonction de l'orientation du flux de chaleur, du flux massique et de la qualité.

La première nouveauté de cette étude est la plus grande précision du modèle ANN développé par rapport aux corrélations empiriques pour la prédiction de HTC, la deuxième nouveauté est la détermination de l'effet de chaque paramètre d'entrée sur HTC, en particulier l'effet de l'orientation sur HTC.

IV.2.2. Matériel et méthode

Un réseau de neurones est un modèle informatique dont la structure en couches est similaire à la structure du réseau de neurones dans le cerveau, avec des couches de nœuds connectés. Un réseau de neurones peut apprendre des données, il peut ainsi être formé pour reconnaître les tendances, classer les données et prédire les futurs évènements [156].

Un réseau de neurones décompose vos données en couches d'abstraction. Il peut être entraîné sur de nombreux exemples afin de reconnaître des modèles dans la parole ou les images, le comportement du réseau de neurones artificiels (ANN) est défini par la façon dont ses éléments individuels sont connectés et par le poids de ces liens [157].

Les poids sont automatiquement ajustés pendant l'entraînement selon une règle d'apprentissage spécifiée jusqu'à ce que le réseau de neurones exécute correctement la tâche souhaitée, L'approche ANN est considérée comme la solution parfaite à tout type de problème dans lequel les associations entre les variables ne sont ni linéaires ni complexes. Dans la structure MLP (Multi Layer Percertron) les neurones sont regroupés en couches, une couche de neurones d'entrée, une autre couche de neurones de sortie et une ou plusieurs couches cachées [158].

Le nombre de neurones dans la couche d'entrée est égal au nombre de variables d'entrée et le nombre de neurones dans la couche de sortie est égal au nombre de variables ciblées, mais le nombre de neurones dans la couche cachée est choisi pour les meilleures performances. Chaque neurone doit être connecté à chaque neurone d'une couche adjacente, les poids synaptiques initiaux sont attribués au hasard à toutes les connexions, les données d'entrée normalisées sont saisies au niveau de la couche d'entrée pour être transmises aux couches cachées via des connexions synaptiques, sachant que la couche de sortie est leur destination finale [159].

Cette étude vise à construire un modèle ANN, capable de prédire le coefficient de transfert de chaleur lors de l'ébullition de l'eau dans un canal rectangulaire incliné en fonction de l'orientation, flux de chaleur, débit massique et qualité (θ: orientation, G: débit massique, Xe: qualité, q: flux de chaleur).

Le nombre de données expérimentales utilisées dans l'ANN est de 520, qui sont divisés en trois sections : l'ensemble d'apprentissage (312 données), l'ensemble de test (104 données) et l'ensemble de validation (104 données). Tab IV.1. montre la plage des variables.

Tableau IV.1. Gamme de variables

	variables	**Unit**	**Min**	**Max**	**incertitudes**
Orientation	θ	[º]	0	90	/
Débit masique	G	[Kg.m^{-2}.S^{-1}]	110	208	0.5%
Flux de chaleur	q	[MW.m^{-2}]	0.1	1.6	1.7%
Qualité	Xe	-	0.003	0.036	2.3%
Coefficient de transfert de chaleur	HTC	[KW.m^{-2}K^{-1}]	8.315	46.55	6.2%

Pour normaliser les données d'entrée dans la plage de [-1, 1], nous avons utilisé l'algorithme mapminmax donné par Eq. (IV.1), mais pour la normalisation des données de sortie, nous avons utilisé la fonction logarithmique et la fonction mapminmax (Eq. (IV.2))

$$y_n = map\min\max(X) = \frac{2.(X - X_{\min})}{(X_{\max} - X_{\min})} - 1 \qquad \text{(IV.1)}$$

Où X est la valeur vectorielle d'origine, X_{max} et X_{min} sont les valeurs maximale et minimale correspondant à X, respectivement, et y_n est la valeur vectorielle normalisée par le vecteur X.

$$HTC_n = map\min\max\left(\ln\left(HTC\right)\right) \qquad \text{(IV.2)}$$

Où HTC_n est la valeur normalisée de la sortie, le réseau est formé par les valeurs d'entrée et de sortie normalisées.

Trouver une architecture de réseau de neurones artificiels optimale est très important en raison de ses effets majeurs sur les résultats [158]. Après l'examen d'un nombre important des réseaux de neurones avec différent structures sachant que l'optimisation des paramètres ANN est réalisée en minimisant l'erreur absolue relative moyenne (MRAE), la structure de réseau de neurones artificiels adéquate qui a été sélectionnée dans cette étude possède 30 neurones dans la couche cachée, la couche cachée a une fonction de transfert tangente sigmoïde. La couche de sortie a une fonction de transfert linéaire et le 'Levenberg-Marquardt' comme algorithme d'apprentissage. La structure optimale du réseau de neurones artificiels est présentée dans le Tab. IV.2.

Tableau IV.2. Architecture du modèle ANN optimisé

Algorithme d'apprentissage	Couche d'entrée	Couche cachée		Couche de sortie	
	Nombre de neurons	Nombre de neurons	Fonction de transfert	Nombre de neurons	Fonction de transfert
Levenberg-Marquardt backpropagation	4	30	Hyperbolic tangent sigmoid	1	Linear

Le modèle ANN développé est donné par la formule suivante Eq. (IV.3).

$$HTC_n = \sum_{j=1}^{j=N_h} \left[V_j . \left(\frac{2}{1+\exp\left(-2.\left(b_j + \sum_{i=1}^{i=N_p} W_{ij} . y_{n_i}\right)\right)} - 1 \right) \right] + b_{out} . \qquad \text{(IV.3)}$$

W_{ij} et V_j sont les poids synaptiques entre la couche d'entrée et la couche cachée et entre la couche cachée et la couche de sortie successivement, b_j et b_{out} sont les vecteurs de biais de la couche cachée et de la couche de sortie.

IV.2.3. Résultats et discussions

Dans ce travail, les performances et la fiabilité du modèle ANN ont été évaluées par divers critères statistiques, notamment l'erreur relative absolue (RAE%), l'erreur relative absolue moyenne (MRAE), l'erreur quadratique moyenne (MSE), le coefficient de corrélation (R), le Coefficient de détermination (R^2) [160].

Le facteur de précision (A_f) et le facteur de biais (B_f) proposés par Ross [161] ont été utilisés comme critères d'évaluation des performances du modèle. Le B_f indique l'accord global entre les valeurs estimées et réelles, un B_f de 1 signifie un accord complet.

Bon modèle :B_f =0.9 – 1.05; Modèle acceptable : B_f = 0.7 – 0.9 ; Modèle à utiliser avec prudence : B_f = 1.06 – 1.15; Modèle inacceptable: B_f < 0.7 and B_f >1.1.

La valeur du facteur de précision A_f sera toujours égale ou supérieure à un car toutes les variances sont positives. La valeur A_f de 1,1 signifie que la valeur estimée est différente de 10 % de la valeur cible.

Le modèle ANN développé a également été évalué par les critères d'acceptabilité *K* et *K'* proposés par les chercheurs [162], le modèle est acceptable si :

$$0.85 \leq K \leq 1.15 \quad \text{and} \quad 0.85 \leq K' \leq 1.15$$

Les résultats de performance des ANN utilisés pour les données d'entraînement, les données de test, les données de validation et toutes les données sont indiqués dans le Tab.IV.3. La valeur du coefficient de corrélation de 0,9997 pour toutes les données indique la fiabilité du modèle ANN et confirme que le modèle est valide. La valeur R^2 de 0,9993 pour toutes les données indique la pertinence du modèle. Les valeurs du facteur de biais (B_f) et du facteur de précision (A_f) sont proches de l'unité, ce qui indique que le modèle est valide dans la prédiction de HTC. Les valeurs de K et K' indiquent que le modèle est acceptable. Les valeurs de l'erreur absolue relative moyenne démontrent la précision du modèle ANN.

Tableau IV.3. Performance statistique de l'ANN.

	Apprentissage	**Test**	**Validation**	**Tous**
RAEmin%	0.0002	0.0054	0.0058	0.0002
RAE_{max}%	4.6615	4.7273	4.5429	4.7273
MRAE%	0.6834	0.6084	0.7910	0.6899
MSE	0.0012	0.0263	0.0151	0.0020
R	0.9997	0.9998	0.9996	0.9997
R^2	0.9993	0.9995	0.9992	0.9993
A_f	1.0069	1.0061	1.0079	1.0069
B_f	1.0002	0.9990	1.0002	1.0005
K	1.0003	1.0005	0.9990	1.0001
K'	0.9996	0.9994	1.0009	0.9998

Table.IV.4 récapitule les valeurs obtenues des poids et des biais (W_{ij}, V_j, b_j et b_{out}) pour l'architecture optimale de réseau de neurones artificiels donnée dans le Table. IV.2.

Ces paramètres sont utilisés dans le modèle ANN développé donné dans l'Eq. (IV.3) pour calculer le coefficient de transfert de chaleur lors de l'ébullition de l'eau dans un canal incliné.

Tableau IV.4. Les valeurs optimales des poids et biais obtenus lors de l'apprentissage de l'ANN

j	Poids synaptiques entre la couche d'entrée et la couche cachée W_{1j}	W_{2j}	W_{3j}	W_{4j}	Biais de couche cachée b_j	Poids synaptiques entre la couche cachée et la couche de sortie V_j	Biais de la couche de sortie b_{out}
1	-1.3117	5.8123	-2.1972	6.0248	9.7987	0.3510	
2	1.5042	-0.3139	-3.1344	2.3667	-4.6555	-2.3514	
3	1.8579	-0.9120	-0.3420	2.7751	-3.1617	2.3875	
4	2.7216	0.3661	-2.8504	-1.5029	-2.5968	-2.1650	
5	-2.9503	-1.7629	2.4108	3.6133	4.4408	2.3816	
6	3.6294	0.6730	-3.2475	-1.0666	-2.8832	1.4117	
7	1.8301	1.7327	-2.6270	-2.5217	-3.3098	2.9724	
8	0.9541	-3.4161	-4.0314	0.9683	2.2023	-0.4536	
9	0.4134	-1.4506	1.8620	-1.0447	-1.8416	-1.0716	
10	-4.1274	0.0097	-3.6633	-1.5042	2.2696	0.2415	
11	1.1978	-0.8278	-0.2641	-2.6551	-0.7530	3.3854	
12	1.8921	-15796	-0.0382	-0.4343	-0.3074	-1.3913	-5.3525
13	3.8155	-1.2136	3.2717	-2.5947	-2.0447	-1.2379	
14	-3.5888	0.2031	-3.6489	0.4966	-1.1658	0.3237	
15	-3.7544	1.0163	0.1521	2.0787	1.3048	-1.3724	
16	-4.1396	-5.2211	-1.9237	-1.1470	1.0978	-0.0379	
17	-5.2853	4.2681	-4.6420	2.0188	-0.4281	-0.0697	
18	0.7786	-2.8529	2.2165	0.9115	0.7849	2.0610	
19	-1.2543	-0.3848	-0.9557	-1.3637	-0.9165	-3.5568	
20	-1.2442	3.9585	-2.9973	-1.2225	-0.8220	1.0742	
21	1.0025	0.8902	0.4770	-1.7181	0.4898	-0.9678	
22	2.8452	-0.6413	-1.6201	2.5124	1.0015	-1.7350	
23	3.3238	1.9422	-0.5087	-1.3597	1.9492	0.5735	
24	1.5642	-1.0487	2.7174	-1.2099	2.7523	-4.1343	
25	2.5044	1.1520	-2.8710	-0.5543	1.6281	-0.9639	
26	0.1314	1.9148	-0.6953	-2.7528	3.5711	0.6669	
27	-0.6939	8.3469	-0.0274	-0.4532	7.4872	0.1112	
28	-4.0681	2.0208	2.7900	-1.3605	-4.6937	-1.6225	
29	0.7754	-4.0405	2.3124	3.6029	5.8716	2.0378	
30	-1.8228	1.2004	-1.7758	2.1135	-3.3714	-2.7929	

L'analyse de régression effectuée entre les valeurs expérimentales et les valeurs prédites de HTC. Les résultats de l'apprentissage, de la validation et du test sont illustrés à la figure IV.1. Ces résultats confirment la grande capacité du modèle ANN utilisé et démontrent un bon ajustement entre les valeurs prédites et expérimentales de HTC.

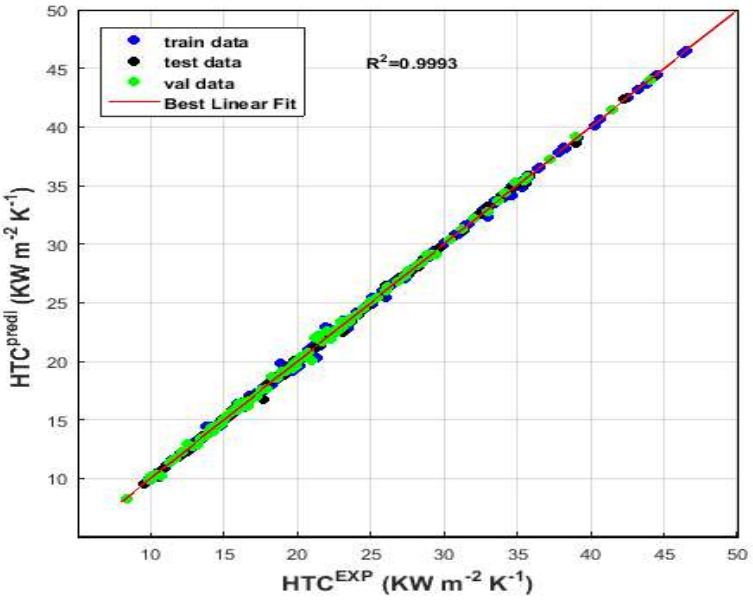


Figure IV.1. Graphiques de régression de l'ANN pour la prédiction du coefficient de transfert de chaleur (Tous les ensembles de données)

Le résidu des valeurs prédites du HTC par rapport aux valeurs expérimentales pour le modèle ANN développé est illustré à la Figure. IV.2. Comme la plupart des résidus calculés sont répartis sur les deux côtés de la ligne zéro, on peut conclure qu'il n'y a pas d'erreur systématique dans l'élaboration du présent modèle.

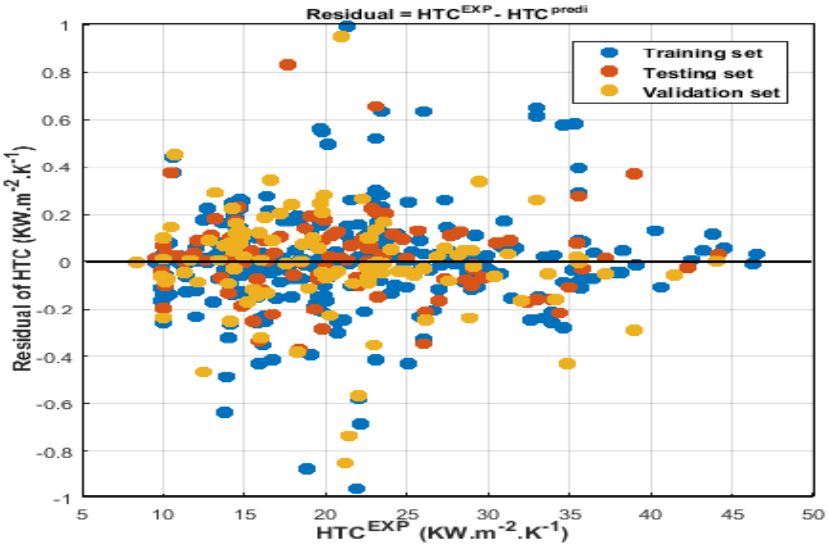


Figure IV.2. Tracé des résidus pour les valeurs calculées de HTC à partir de l'ANN modèle par rapport à leurs valeurs expérimentales pour les ensembles d'apprentissage, de test et de validation

Le graphe de probabilité normale de la prédiction du modèle ANN de HTC est illustré à la figure 3. Dans une probabilité normale, presque une ligne diagonale droite est formée par les points de données qui montrent des données normalement distribuées. Comme le montre la figure IV.3, de nombreux points de données sont très proches de la valeur résiduelle zéro, ce qui indique des erreurs minimales dans le modèle ANN développé.

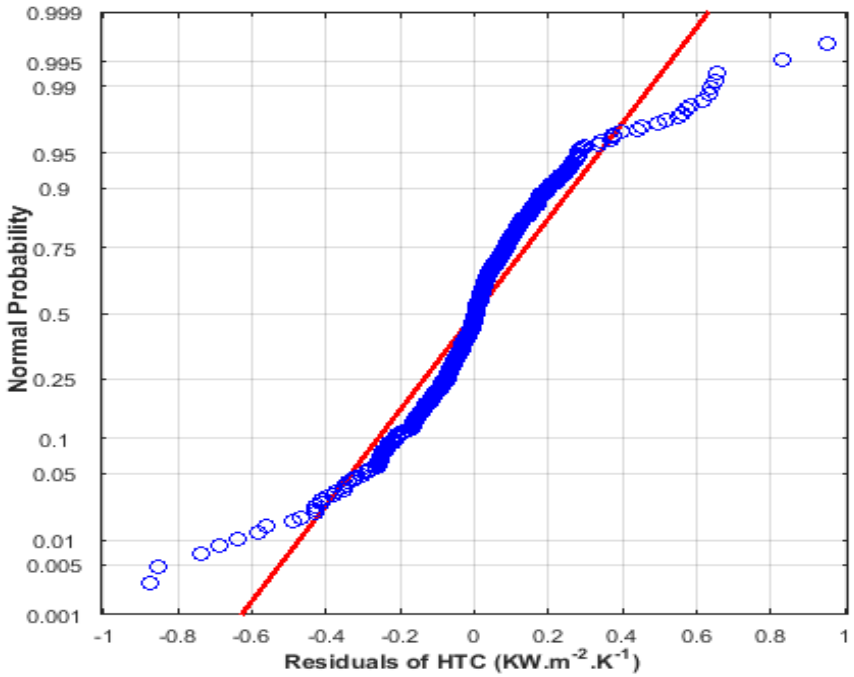


Figure IV.3. Diagramme de probabilité normale du modèle ANN pour prédire HTC

Les résultats de prédiction typiques du modèle ANN développé concernant l'influence de l'orientation (θ) et du flux de chaleur (q) sur le coefficient de transfert de chaleur sont illustrés à la Fig.IV.4, d'après la figure, il est clair que le coefficient de transfert de chaleur est presque constant entre 0º et 30º, mais dans la plage de 30º à 70º , le HTC augmente énormément et la variation de HTC entre 70º et 90º est très faible, il est également clair que l'augmentation du flux de chaleur provoque l'augmentation de HTC. Ces résultats sont presque compatibles avec les résultats de Gong et al. [46].

Les résultats de prédiction typiques du modèle ANN développé concernant l'influence du flux massique (G) et de la qualité (Xe) sur le coefficient de transfert de chaleur sont présentés dans les Fig. IV.5 et Fig. IV.6, à partir des figures nous montrons que l'effet du flux massique et de la qualité sur le HTC sont faibles, ces résultats sont similaires aux résultats rapportés dans la littérature [46].

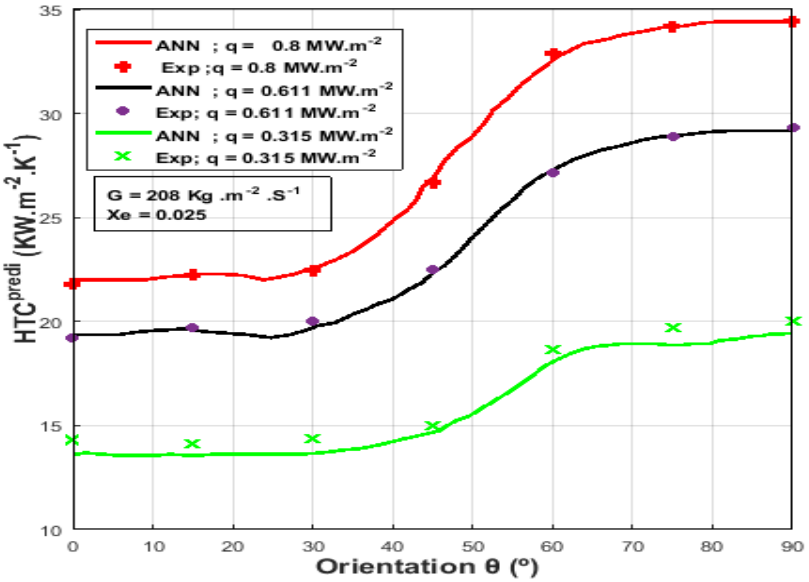


Figure IV.4. L'effet d'orientation sur le HTC

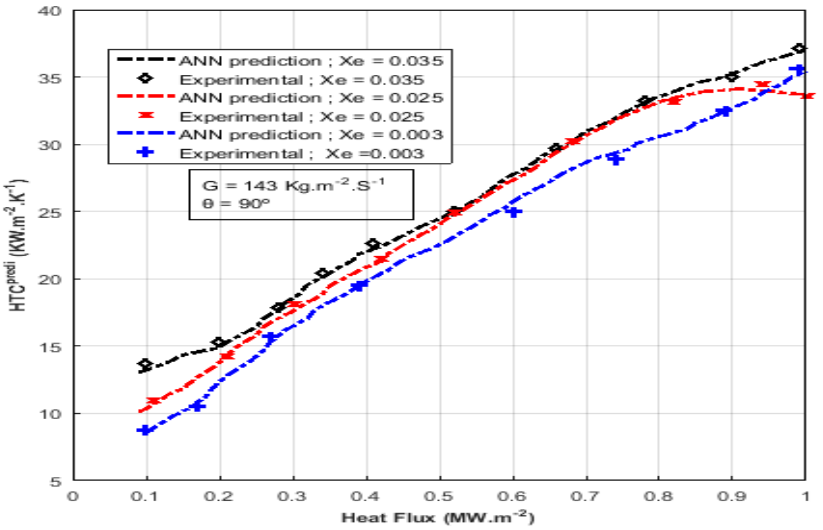


Figure IV.5. L'effet de qualité sur le HTC

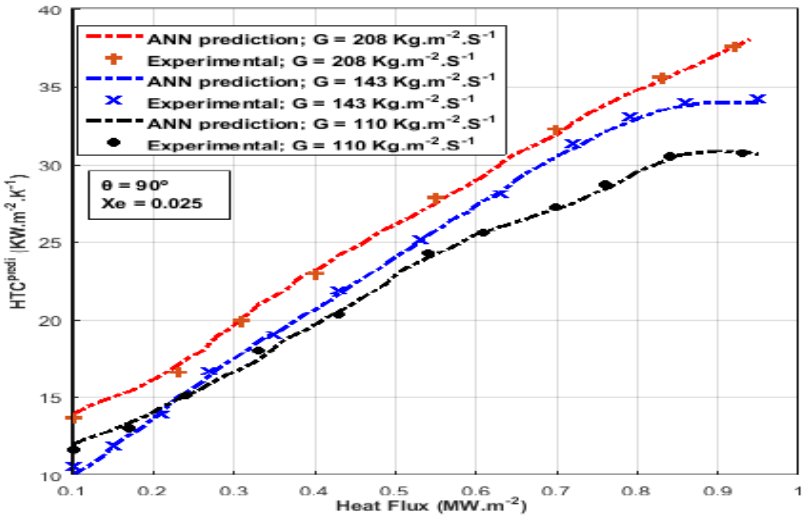


Figure IV.6. L'effet de débit massique sur le HTC

IV.2.3.1. Validation du modèle ANN

Pour valider le modèle ANN développé, nous l'avons comparé avec les corrélations empiriques de HTC d'un écoulement saturé en ébullition [67, 68, 71] et les données expérimentales de Gong et al. [46] pour un canal vertical, la comparaison est illustrée à la Fig. IV.7, le modèle a également été comparé aux résultats expérimentaux de Gong et al. [46] pour les différentes orientations, la comparaison est illustrée à la Fig. IV.8. A partir des deux figures, nous pouvons voir la précision et la validité du modèle neuronal développé pour la prédiction de HTC lors de l'ébullition de l'eau dans un canal incliné.

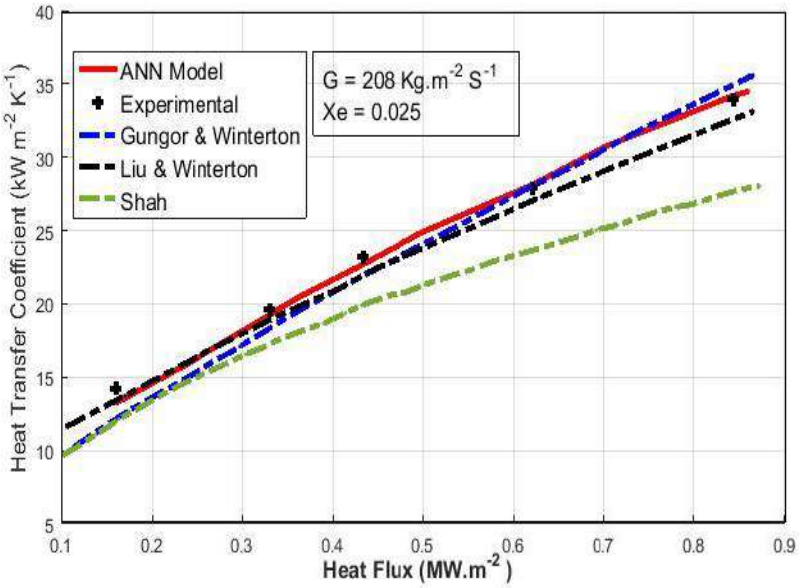


Figure IV.7. Comparaisons de la prédiction ANN de HTC avec des données expérimentales et des corrélations empiriques dans le canal verticale

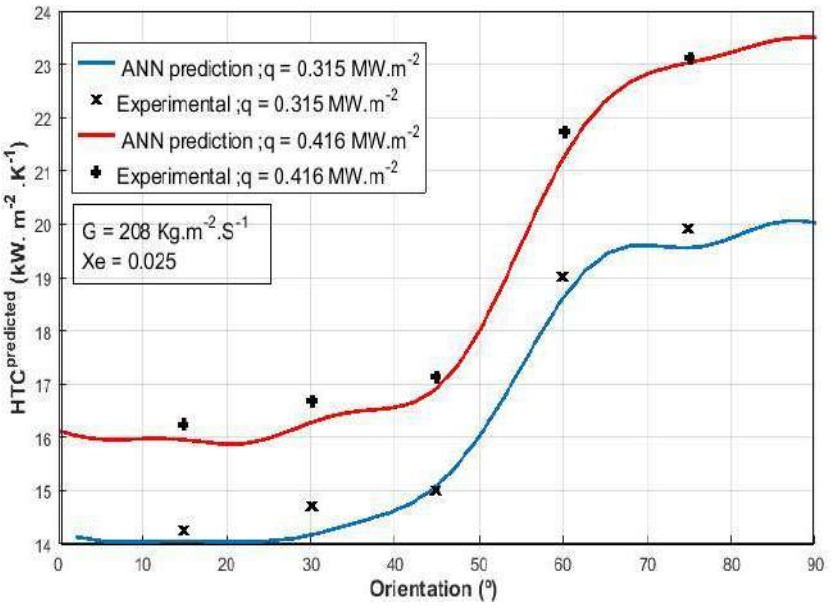


Figure IV.8. Comparaisons de la prédiction de l'ANN de l'effet d'orientation sur HTC avec les résultats expérimentales

IV.2.3.2. Détermination de l'importance de chaque variable d'entrée

Les valeurs des poids des réseaux de neurones permettent de connaître l'importance relative des différentes variables d'entrée (Orientation, Flux massique, Flux de chaleur, Qualité) sur la variable de sortie (Coefficient de transfert thermique), une équation basée sur le partitionnement des poids de connexion anticipé par Garson [163]**.**

$$\mathrm{Im}\, p_t = \frac{\sum_{j=1}^{N_h}\left(\left(\left|W_{tj}\right| / \sum_{i=1}^{N_p}\left|W_{ij}\right|\right).\left|V_j\right|\right)}{\sum_{i=1}^{N_p}\left\{\sum_{j=1}^{N_h}\left(\left(\left|W_{tj}\right| / \sum_{i=1}^{N_p}\left|W_{ij}\right|\right).\left|V_j\right|\right)\right\}} \qquad \text{(IV.4)}$$

Où imp_t est l'importance relative de la variable d'entrée " t " sur la variable de sortie, N_p et N_h sont respectivement le nombre de neurones d'entrée et cachés, les W_{ij} sont les poids de connexion entre la couche d'entrée et la couche cachée, V_j sont les poids de connexion entre la couche cachée et la couche de sortie. Notez que le numérateur dans (Eq. (IV.4**)**) décrit la somme des produits des poids absolus pour chaque entrée, Cependant, le dénominateur est le total de tous les poids alimentant l'unité cachée, en prenant les valeurs absolues [164]. Un résumé des résultats obtenus est présenté dans la Fig.IV.9.

On peut voir que l'orientation a de forts effets sur la valeur du coefficient de transfert de chaleur avec une importance égale à 27%, mais le flux de chaleur et la qualité et le débit massique ont presque le même effet sur la valeur du coefficient de transfert de chaleur avec une importance égale à 19 et 25 et 28% respectivement.

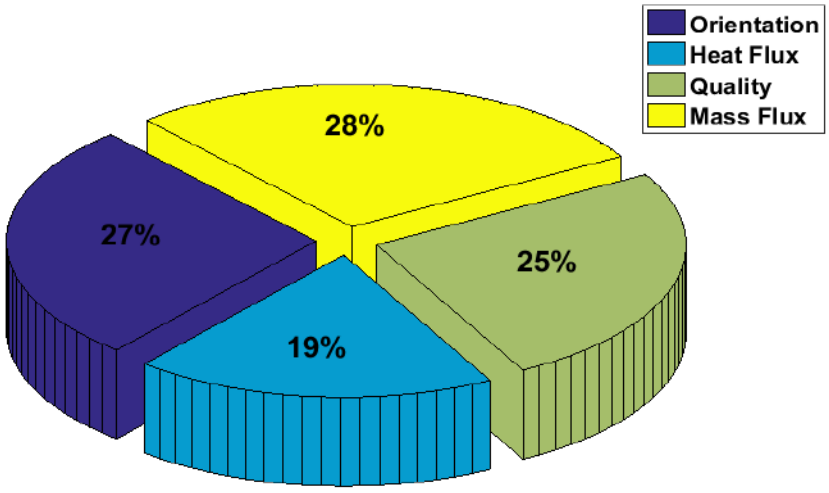


Figure IV.9. Importance relative des variables d'entrée sur la sortie

IV.2.3.3. Programme informatique pour calculer HTC

Un programme informatique a été développé utilisant le logiciel MATLAB dans le but d'utiliser le modèle neuronal avec plus de flexibilité, Cela donne à l'utilisateur toutes les entrées nécessaires à l'exécution du modèle (θ : orientation, q : flux de chaleur, Xe : qualité, G : débit massique) pour prédire le coefficient de transfert de chaleur lors de l'ébullition de l'eau dans un canal rectangulaire incliné.

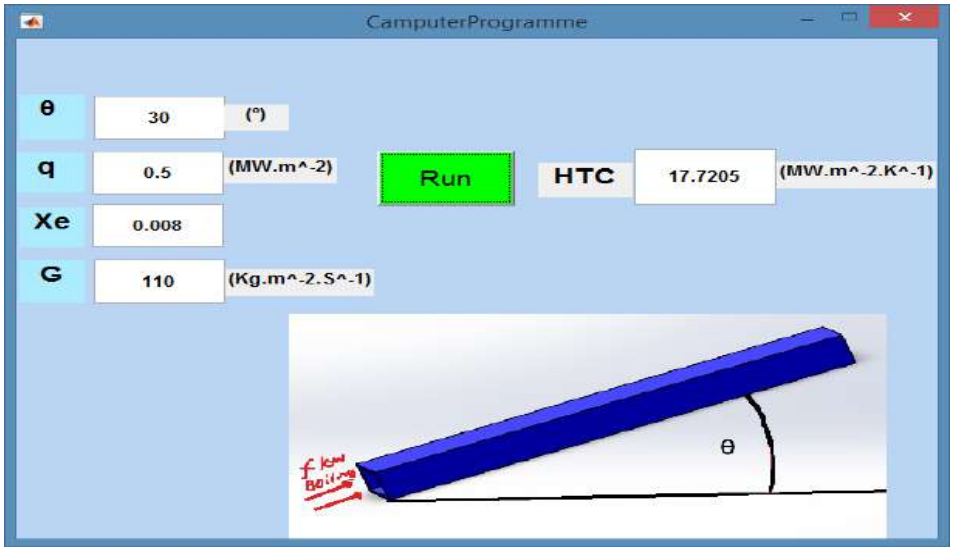


Figure IV.10. Interface Matlab pour le calcule de HTC

IV.2.4. Conclusion

Dans ce travail, nous avons développé un modèle neuronal de prédiction du coefficient de transfert de chaleur lors de l'ébullition de l'eau dans un canal incliné, en fonction de l'orientation, du flux de chaleur, de la faible qualité d'équilibre et du faible flux de masse. La comparaison entre les données expérimentales et les données prédites par le réseau de neurones montre les performances de l'architecture de réseau utilisée.

Le modèle optimale a été obtenu avec la structure 4-30-1 en tenant compte de l'algorithme d'apprentissage de rétro-propagation de Levenberg-Marquardt et de la fonction de transfert tangente sigmoïde dans la couche cachée et de la fonction de transfert linéaire dans la couche de sortie. Un total de 520 points de données expérimentales a été collecté à partir de la littérature afin d'utiliser dans le modèle ANN comme points de données d'apprentissage, de validation et de test.

Une erreur absolue relative moyenne (MRAE) de 0,68 % et un coefficient de corrélation (R) de 0,9997 ont été obtenus par le modèle ANN pour tous les ensembles de données.

Nous concluons que l'effet d'orientation sur HTC est très important dans la région entre 30º et 70º, nous concluons également que les effets de débit massique et de qualité sur HTC sont faibles.

La validité du modèle ANN est démontrée dans sa comparaison avec certaines corrélations empiriques pour le canal vertical et avec les résultats expérimentaux pour diverses orientations.

IV.3. Modélisation de l'ébullition en film

IV.3.1. Introduction

L'ébullition en film se produit lorsqu'un film de vapeur complet existe entre la surface chauffée et le liquide bouillant. L'ébullition pelliculaire en écoulement est divisée en une ébullition pelliculaire à flux dispersé (DFFB) formée à une fraction de vide élevée, et une ébullition pelliculaire annulaire inversée (IAFB) formée à une fraction de vide faible, l'ébullition pelliculaire annulaire inversée est caractérisée par un film de vapeur recouvrant la surface chauffante.

Ce travail étant l'application du réseau de neurones artificiels pour développer un modèle de prédiction du coefficient de transfert de chaleur en fonction de la pression, du flux de chaleur, du débit massique et de la qualité pendant l'ébullition pelliculaire (à la fois IAFB et DFFB) d'eau dans un tube vertical ID 8 mm.

IV.3.2. Approche neuronale

L'approche RNA est considérée comme la solution parfaite à tout type de problème dans lequel les associations entre les variables ne sont pas linéaires. Dans la structure MLP, les neurones sont regroupés en couches, une couche de neurones d'entrée, une autre couche de neurones de sortie et une ou plusieurs couches cachées. Ils sont créés par de nombreux neurones interconnectés. La normalisation des valeurs est une étape cruciale dans la conception des RNA. Les données d'entrée et de sortie ont été normalisées par l'utilisation d'un algorithme mapminmax, les variables de sortie sont normalisées par la fonction log [165].

Cette étude vise à construire un modèle ANN, capable de prédire le coefficient de transfert de chaleur lors de l'ébullition pelliculaire. Le nombre de données observées utilisé dans l'ANN est de 20 000 divisé en trois sections : l'ensemble d'apprentissage (15 600 données), l'ensemble de test (2 200 données) et l'ensemble de validation (2 200 données). Le tableau IV.5 montre l'éventail des variables.

Tableau IV.5. Gamme de variables [166]

paramétres	variables	Unité	Min	Max
Pression	P	kPa	100	20000
Débit massique	G	kg/m^2s	0	7000
Flux de chaleur	q	kW/m^2	50	3000
qualité	Xe	-	-0.2	1.2
coefficient de transfert de chaleur	HTC	kW/m^2K	0.046	85.966

Trouver une architecture RNA optimale est très important en raison de ses effets majeurs sur les résultats. La figure 1 montre les performances de différentes configurations de modèles RNA avec un nombre différent de neurones dans les couches cachées.

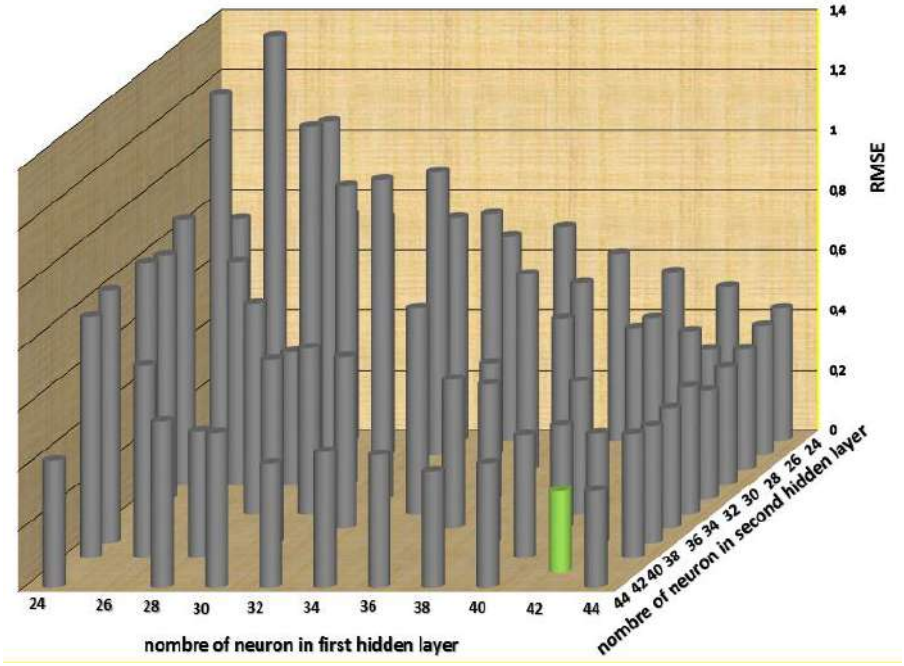


Figure IV.11. L'effet du nombre de neurone dans les couches cachées sur RMSE

Le tableau IV.6 montre l'effet des algorithmes d'apprentissage sur les performances du réseau. Les algorithmes d'apprentissage étudiés sont : Rétropropagation de Levenberg–Marquardt (trainlm), rétropropagation de régularisation bayésienne (trainbr), rétropropagation de gradient conjugué Powell–Beale (traincgb), rétropropagation de gradient conjugué Fletcher–Reeves (traincgf), rétropropagation de gradient conjugué Polak–Ribiere (traincgp). Rétropropagation de gradient conjugué à l'échelle (trainscg), Descente de gradient par lots (traingd), Descente de gradient avec rétropropagation de taux d'apprentissage adaptatif (traingda), Descente de gradient par lots avec élan (traingdm), Rétropropagation de taux d'apprentissage variable (traingdx), Une sécante en arrière propagation (trainoss), rétropropagation résiliente (trainrp), rétropropagation quasi-Newton BFGS (trainbfg).

Après l'examen d'un nombre important des réseaux de neurones avec différent nombre de neurones dans les couches cachées, et avec différent algorithmes d'apprentissage et également avec différent fonctions de transfert, l'architecture optimale qui ont été sélectionnés dans cette étude à une double couche cachée avec 42 neurones pour chacun et bien sûr une couche de sortie avec un neurone. Les couches cachées à une fonction de transfert "logsig". La couche de sortie a une fonction de transfert purelin et le 'Levenberg-Marquardt' comme algorithme d'apprentissage. La fonction de performance

du modèle RNA dans cette étude est l'erreur quadratique moyenne (RMSE) entre les sorties RNA et les sorties ciblées (entraînement supervisé).

Tableau IV.6. L'effet d'algorithme d'apprentissage sur la performance du RNA

Algorithme d'apprentissage		RMSE	Nbr d'eteration	Coefficient de correlation (R)
1	trainlm	0.270	1000	0.99963
2	trainbr	1.1324	1000	0.99709
3	traincgb	1.5444	1000	0.9884
4	traincgf	6.297	1000	0.99414
5	traincgp	1.9635	1000	0.99408
6	trainscg	3.13	1000	0.99546
7	traingd	7.214	1000	0.71346
8	traingda	5.221	1000	0.75503
9	traingdm	5.708	1000	0.74039
10	traingdx	4.122	1000	0.87411
11	trainoss	2.314	1000	0.99143
12	trainrp	2.214	1000	0.96801
13	trainbfg	1.1200	1000	0.99601

La structure typique d'un réseau de neurones artificiels est illustrée à la Fig. IV.12. Quatre variables d'entrée (P : Pression, G : Débit massique, q : Flux de chaleur et Xe : Qualité d'équilibre), tandis que le coefficient de transfert de chaleur a été introduit comme variable de sortie.

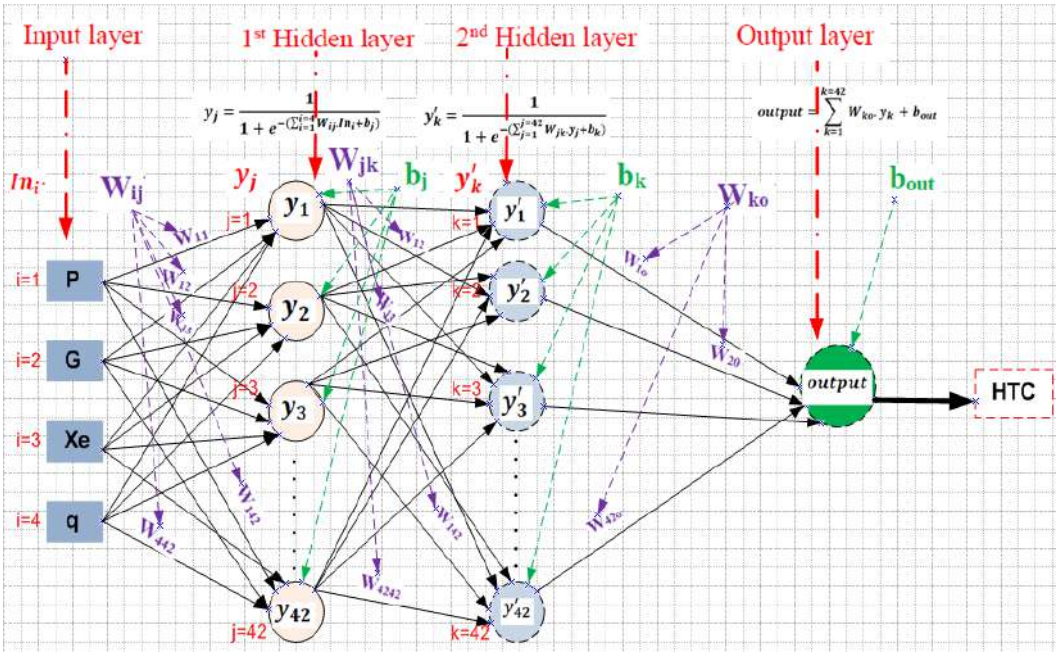


Figure IV.12. Structure optimale du modèle RNA

le modèle élaboré est donné par la formule de l'Eq. (IV.5).

$$HTC = \sum_{k=1}^{k=42} W_{ko} \cdot \left(\frac{1}{1+e^{-\left(\sum_{j=1}^{j=42} W_{jk} \cdot \left(\frac{1}{1+e^{-\left(\sum_{i=1}^{i=4} W_{ij}.In_i + b_j \right)}} \right) + b_k \right)}} \right) + b_{out} \qquad \text{(IV.5)}$$

Où HTC représente le coefficient de transfert de chaleur, In_i représente les différentes entrées (Pression, Débit massique, Flux de chaleur et Qualité) ,W_{ij} est les poids synaptiques entre la couche d'entrée et la première couche cachée, W_{jk} est les poids synaptiques entre la première couche cachée et la deuxième couche cachée ,W_{ko} est les poids poids synaptiques entre la deuxième couche cachée et la couche de sortie , b_j et b_k et b_k représentent les matrices de biais de la première couche cachée et de la deuxième couche cachée et de la couche de sortie respectivement.

IV.3.3. Critères de performances statistiques

Les performances et la fiabilité du modèle RNA sont basées sur plusieurs critères statistiques. La racine d'erreur quadratique moyenne (RMSE), le coefficient de corrélation (R), l'erreur absolue AE, l'erreur absolue moyenne AAE, le coefficient de détermination (R^2), Facteur de précision (Af), Facteur de biais (B_f), les critères d'acceptabilité k et k', l'écart type STDEV sont donnés par les formules suivantes:

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^{n} \left(y_i - y_i^t \right)^2 \right]^{1/2} \qquad \text{(IV.6)}$$

$$AE_i = \left[\frac{\left\| y_i^t \right| - \left| y_i \right\|}{\left| y_i^t \right|} \right] .100 \qquad \text{(IV.7)}$$

$$AAE = \frac{1}{n} \sum_{i=1}^{n} AE_i \qquad \text{(IV.8)}$$

$$STDEV = \left[\frac{n \sum_{i=1}^{n} (AE_i)^2 - \left(\sum_{i=1}^{n} AE_i \right)^2}{n(n-1)} \right]^{1/2} \qquad \text{(IV.9)}$$

IV.3.4. Résultats et discussions

Les critères de performance statistique comprenant R, R^2, STDEV, RMSE, A_f, Bf, K, K', AAE et les valeurs maximales et minimales de AE pour la phase d'apprentissage, la phase de validation et la phase de test ont été calculés et présentés dans le tableau IV.7.

Tableau IV.7. Performances statistiques du modèle RNA

	Apprentissage	Test	Validation
AE_{min}%	0.00030	0.0039	0.0012
AE_{max}%	7.3795	8.3886	9.9461
AAE%	1.9616	2.6617	3.8074
RMSE	0.2184	0.2144	0.0200
R	0.9996	0.9993	0.9992
R^2	0.9992	0.9987	0.9985
STDEV%	1.6172	2.3896	2.6897
A_f	1.0193	1.0270	1.0273
B_f	0.9998	1.0007	0.9993
K	0.9999	1.0018	0.9985
K'	1.0004	0.9973	1.0004

Les résultats obtenus ont montré que le modèle RNA est capable de prédire le coefficient de transfert de chaleur. La grande capacité et la validité du modèle ANN sont clairement démontrées.

Les graphes de régression, illustrés à la Fig. IV.13, Fig. IV.14 et Fig. IV.15 montrent les prédictions du modèle RNA et les valeurs expérimentales pour les trois ensembles de données (apprentissage, validation, test) respectivement.

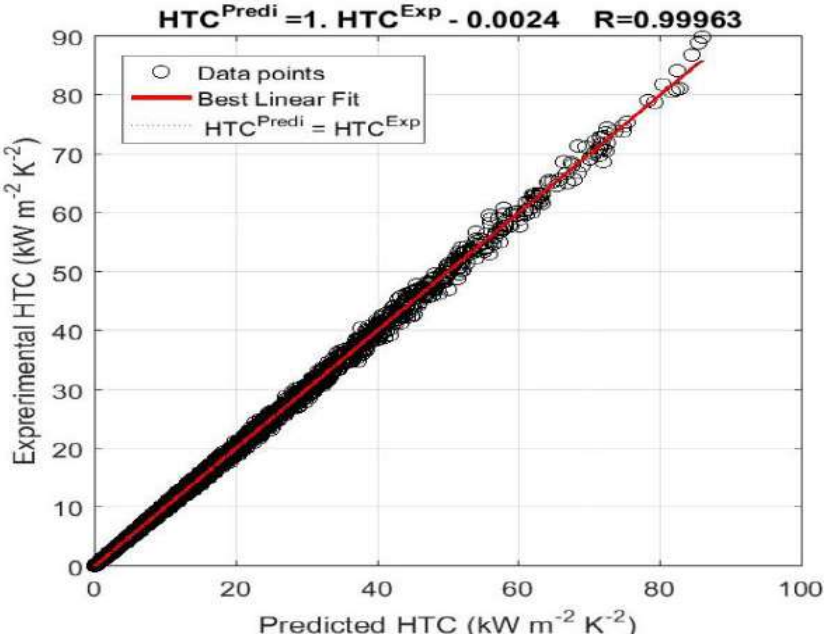


Figure IV.13. Graphe de régression du RNA modèle (apprentissage)

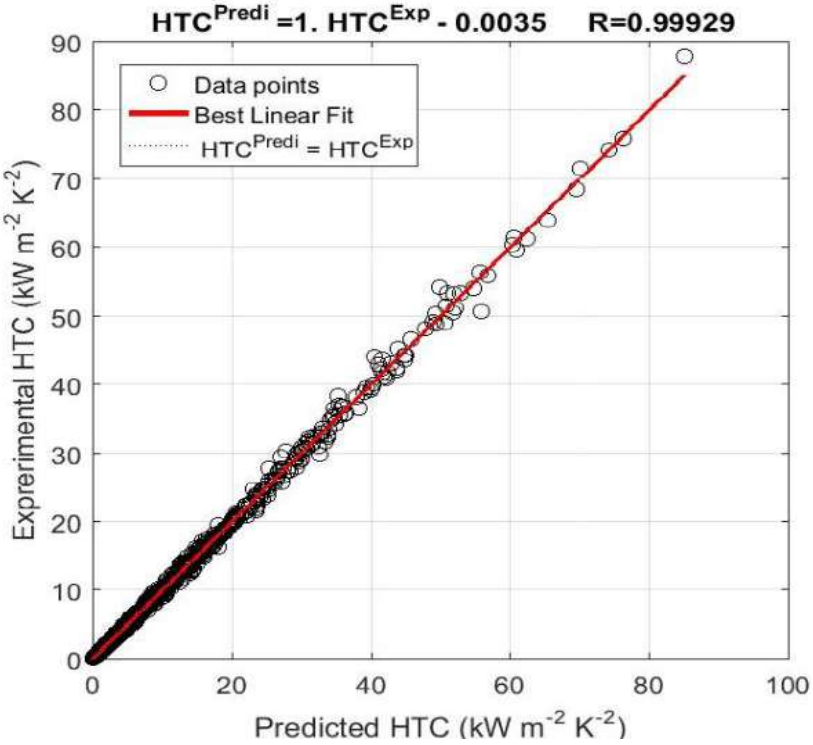


Figure IV.14. Graphe de régression du RNA modèle (validation)

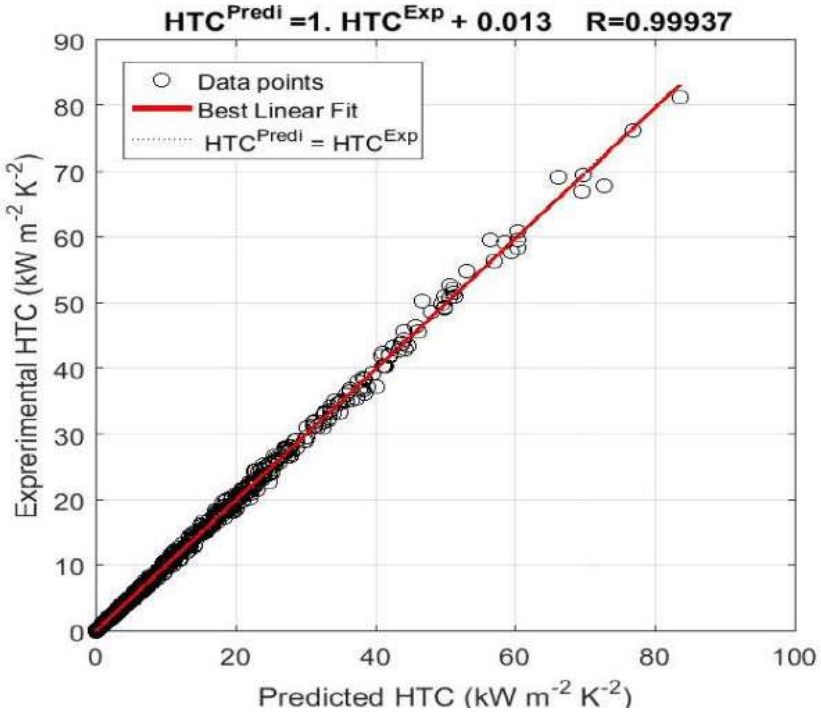


Figure IV.15. Graphe de régression du RNA modèle (test)

Les points doivent se situer le long de la ligne rouge, où les valeurs expérimentales sont égales aux prédictions ANN. Comme indiqué, les résultats sont très bons pour trois ensembles de données (apprentissage, validation, test) car les valeurs R dans chaque cas sont supérieures à 0.999.

Les résultats obtenus montrent les performances du modèle neuronal développé pour la prédiction du coefficient de transfert de chaleur.

La distribution d'erreur absolue de tous les points de données est présentée dans la Fig.IV.16. Comme indiqué, 33,3% des prédictions RNA étaient dans la plage d'erreur de 0-1% et 58,9% de la prédiction du modèle RNA dans la plage d'erreur de 0-2% et 85,5% de la prédiction du modèle RNA dans la plage d'erreur de 0-4% .

On peut conclure que le modèle ANN peut être utilisée comme un outil compétent pour prédire le coefficient de transfert de chaleur.

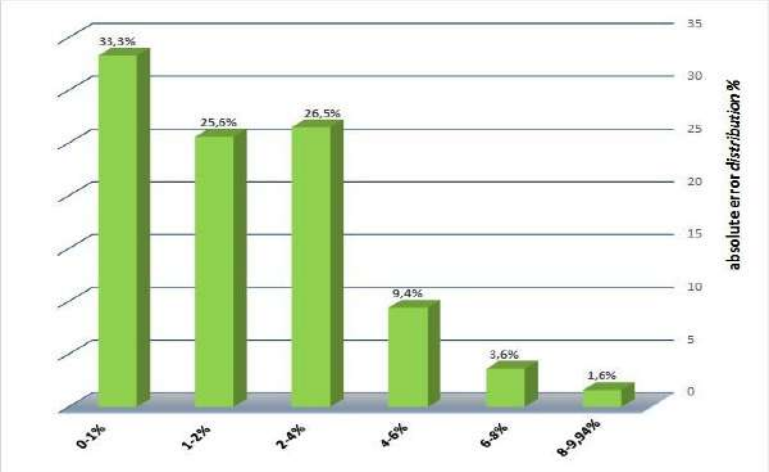


Figure IV.16. Distribution de l'erreur absolue AE%

La figure IV.17 montre l'effet de la pression sur le coefficient de transfert de chaleur à différent qualités d'équilibre. Il montre que le coefficient de transfert de chaleur augmente avec l'augmentation de la pression et de la qualité, le coefficient de transfert de chaleur reste presque constant pour une qualité inferieur à zéro, la figure montre une bonne accordance entre les prédictions du modèle RNA et les valeurs expérimentales.

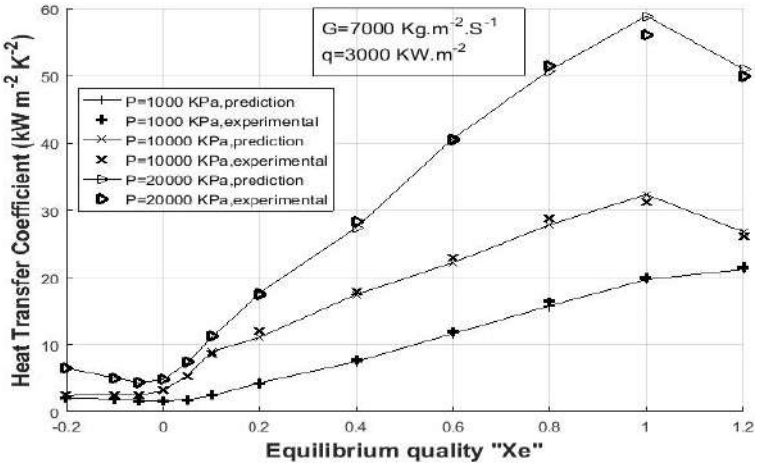


Figure IV.17. L'effet de la pression sur HTC

L'effet du flux de chaleur sur le coefficient de transfert de chaleur est présenté sur la figure IV.18, il est clair que le coefficient de transfert de chaleur diminue avec l'augmentation du flux de chaleur. On constate aussi la validité du modèle développé dans la comparaison des prédictions et les données expérimentales.

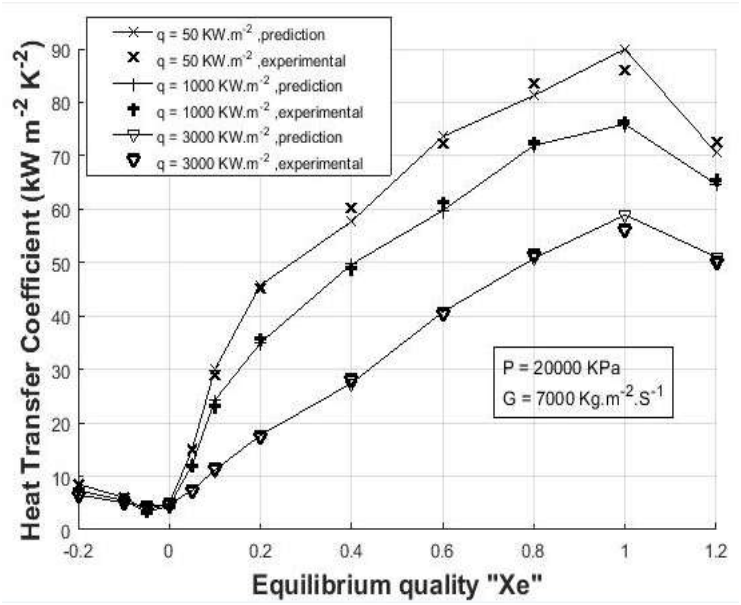


Figure IV.18. L'effet de flux de chaleur sur HTC

L'effet du débit massique et de la qualité sur le coefficient de transfert de chaleur est présenté sur la figure IV.19, on constate que la croissance de débit massique et de qualité provoque une croissance du coefficient de transfert de chaleur.

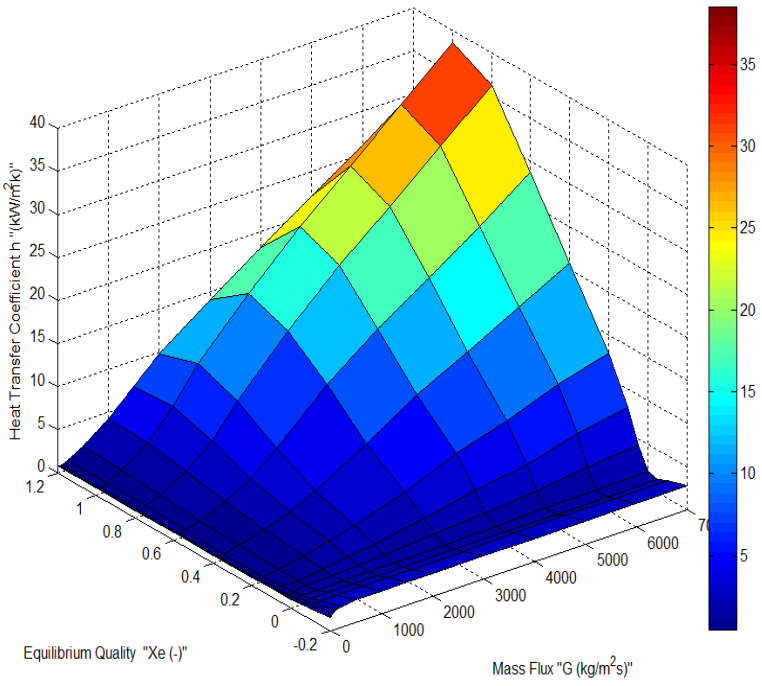


Figure IV.19. L'effet de débit massique et de qualité sur HTC

La matrice des poids synaptiques du réseau de neurones permet de connaître l'importance relative des différentes variables d'entrée (Pression, Débit massique, Flux de chaleur, Qualité d'équilibre) sur la variable de sortie (coefficient de transfert de chaleur), une équation basée sur partitionnement des poids synaptiques proposé par Garson [163].

$$Ij = \frac{\sum_{m=1}^{m=N_h} \left(\left(\left| w_{j_m}^{i_h} \right| / \sum_{K=1}^{N_i} \left| w_{k_m}^{i_h} \right| \right) \times \left| w_{m_n}^{h_o} \right| \right)}{\sum_{k=1}^{k=N_i} \left\{ \sum_{m=1}^{m=N_h} \left(\left(\left| w_{j_m}^{i_h} \right| / \sum_{K=1}^{N_i} \left| w_{k_m}^{i_h} \right| \right) \times \left| w_{m_n}^{h_o} \right| \right) \right\}} \qquad \text{(IV.10)}$$

Où I_j est l'importance relative de la variable d'entrée J sur la variable de sortie, N_i et N_h sont les nombres de neurones d'entrée et cachés respectivement, les W_s sont les poids synaptiques, les exposants 'i', 'h', 'o', se réfèrent aux couches d'entrée, couche cachées et couche de sortie respectivement, et les indices « k », « m » et « n » se réfèrent aux neurones d'entrée, cachés et de sortie respectivement.

Notez que le numérateur dans l'équation (IV.10) décrit la somme des produits des poids absolus pour chaque entrée. Cependant, le dénominateur est le total de tous les poids alimentant l'unité cachée, en prenant les valeurs absolues [164]. Un résumé des résultats obtenus est présenté dans la Fig. IV.20. On peut voir que la pression à de forts effets sur la valeur du coefficient de transfert de chaleur avec une importance égale à 35%, mais le flux de chaleur et le débit massique et la qualité ont presque le même effet sur la valeur du coefficient de transfert thermique avec une importance égale à 23 et 20 et 22% respectivement.

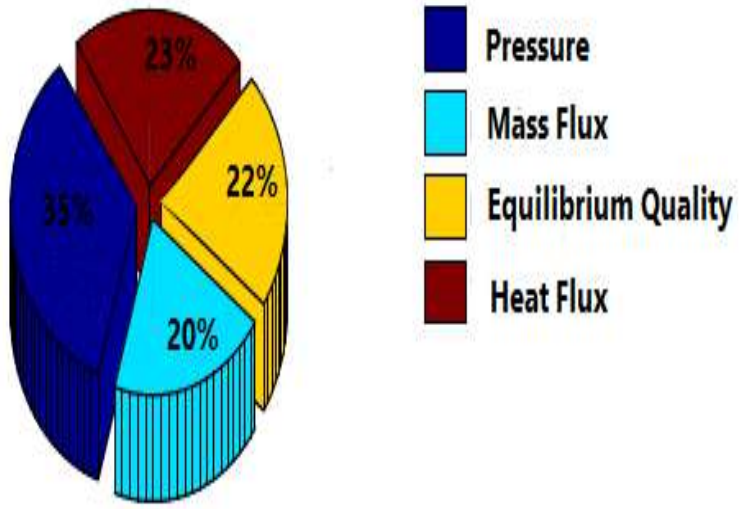


Figure IV.20. L'importance des variables d'entrée sur HTC

IV.3.4.1. Programme de calcule du coefficient de transfert de chaleur en ébullition en film

Pour utiliser le modèle neuronal développé avec plus de flexibilité, un programme informatique a été développé sous MATLAB, Cela donne à l'utilisateur toutes les entrées nécessaires à l'exécution du modèle (P : pression, G : Débit massique, Xe : qualité d'équilibre, q : flux de chaleur) pour prédire le coefficient de transfert thermique lors de l'ébullition pelliculaire de l'eau dans le tube ID 8mm (Fig.IV.21).

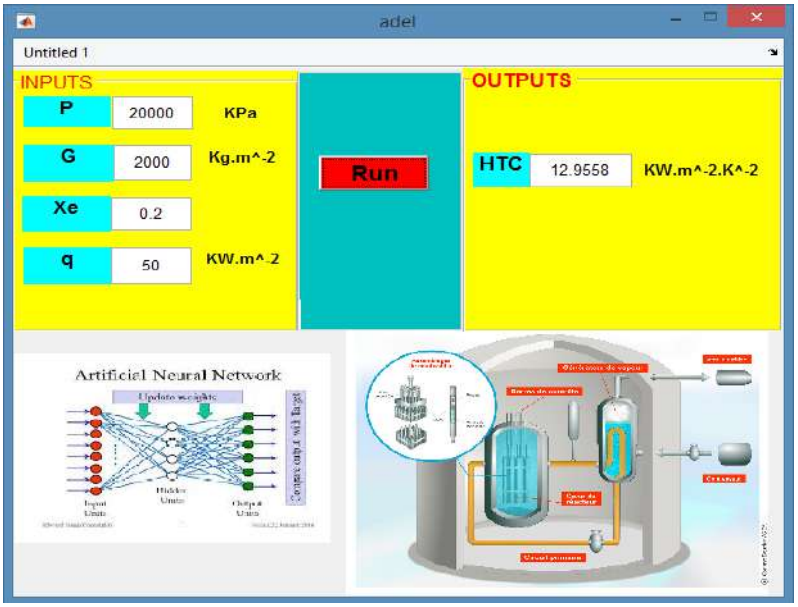


Figure IV.21. Interface Matlab pour le calcul du coefficient de transfert thermique

IV.3.5. Conclusion

Dans ce travail nous avons développé un modèle neuronal de prédiction du coefficient de transfert thermique d'un écoulement en ébullition en film dans un tube vertical de 8 mm de diamètre, en fonction du flux de chaleur, du débit massique, de la qualité d'équilibre et de la pression. La comparaison entre les données expérimentales et les données prédites par le réseau de neurones montre les performances de l'architecture de réseau utilisée.

Le modèle ANN avec deux couches cachées et formé par l'algorithme trainlm a été utilisée pour la prédiction du coefficient de transfert de chaleur. 20 000 points de données ont été collectés à partir de la littérature pour être utilisés dans le modèle ANN comme points de données de l'apprentissage, de validation et de test. La comparaison entre les valeurs de coefficient de transfert de chaleur calculé par le modèle RNA développé et les valeurs expérimentales a montré un bon accord.

IV.4. Modélisation de l'ébullition des nanofluides par RNA

IV.4.1. Introduction

Comme il est nécessaire d'étudier le processus de transfert de chaleur par ébullition, ce travail vise à développer un modèle de réseau de neurones artificiels pour prédire le coefficient de transfert de chaleur (HTC) lors de l'ébullition en écoulement de différents nanofluides à base d'eau dans un tube horizontal.

Le modèle développé est valable pour des valeurs de conductivité thermique de nanoparticules comprises entre 8,4 et 429 [$W.m^{-1}.K^{-1}$], des valeurs de concentration volumétrique entre 0 et 3%, des valeurs de débit massique entre 6,25 et 143,23 [$Kg.m^{-2}.S^{-1}$], et pour les valeurs de flux de chaleur comprises entre 0,25 et 5 [$MW.m^{-2}$]. Plusieurs critères de performances statistiques ont été utilisés dans ce travail pour évaluer le modèle neuronal développé qui a confirmé son exactitude pour la prédiction de HTC. Pour déterminer l'importance relative des variables d'entrée sur le coefficient de transfert de chaleur, une méthode statistique a été mise en place. Le modèle développé a été comparé avec les corrélations empiriques de la littérature et avec d'autres modèles ANN, la comparaison a montré la précision et la validité de ce modèle pour différents nanofluides à base d'eau.

IV.4.2. Description du modèle RNA

Les réseaux de neurones artificiels sont l'un des principaux outils utilisés dans l'apprentissage automatique. Leur fonctionnement est similaire au système nerveux humain [167], Une structure de réseau de neurones artificiels à trois couches est illustrée à la Fig.IV.22, qui se compose des couches "i", "h" et "o" avec des poids W_{ih} et V_{ho}, la procédure d'apprentissage se fait en comparant les variables ciblées avec les sorties de réseau. Les erreurs sont rétropropagées pour calculer les poids synaptiques optimaux par la minimisation de l'erreur quadratique moyenne [168]. L'entrée de la couche cachée "h" est mesurée par la somme pondérée des sorties de la couche d'entrée "i" puis attribuée à chaque neurone de la couche cachée et de la couche de sortie. Par exemple, le y dans la couche cachée "h" est calculé comme suit :

$$y_h = \sum_{i=1}^{I} W_{ih}.X_i + b_h \qquad \text{(IV.11)}$$

Où b_h représente le vecteur de biais de la couche cachée, W_{ih} représente les poids entre la couche d'entrée et la couche cachée, Xi représente la $i^{ème}$ sortie de la couche d'entrée. Une fonction d'activation non linéaire est appliquée à y, et la sortie g(y) est calculée à partir de chaque neurone dans les couches cachées et de sortie [169]. Les fonctions d'activation populaires sont :

$$g(y) = \log sig(y) = \frac{1}{1+\exp(-y)} \quad \text{(IV.12)}$$

$$g(y) = \tan sig(y) = \frac{2}{1+\exp(-2y)} - 1 \quad \text{(IV.13)}$$

Ce travail vise à trouver un modèle précis qui peut prédire le coefficient de transfert de chaleur d'ébullition d'écoulement de nanofluides à base d'eau dans un tube horizontal. Les données sont collectées à partir des travaux de Manish Dadhich et al. [124] et Baniamerian [123]. La gamme de variables est présentée dans le tableau IV.8. et la conductivité thermique des nanoparticules utilisées est présentée dans le tableau IV.9.

Tableau IV.8. Gamme de variables

	variables	Unit	Min	Max
Conductivité thermique des nanoparticles	λ	$[W.m^{-1}.K^{-1}]$	8.4	429
Débit massique	G	$[Kg.m^{-2}.S^{-1}]$	6.25	143.23
Heat flux	q	$[MW.m^{-2}]$	0.255	5
Concentration voulumétrique %	C	-	0	3
Coefficient de transfert de chaleur	HTC	$[KW.m^{-2}K^{-1}]$	1.69	69.37

Tableau IV.9. La conductivité thermique des nanoparticles utilisées

nanoparticles	TiO_2	CuO	Al_2O_3	Cu	Ag
$\lambda\ [W.m^{-1}.K^{-1}]$	8.4	18	36	390	429

Le nombre total de données utilisées dans la procédure de modélisation est de 354. Ces données sont divisées en trois sections. L'ensemble d'apprentissage (284 données), l'ensemble de test (35 données) et l'ensemble de validation (35 données). La normalisation des valeurs est une étape cruciale dans ANN [148]. Les données sont normalisées dans la plage de [-1, 1] par l'utilisation de l'algorithme mapminmax donné par Eq. (IV.14) et Eq. (IV.15).

$$input_n = map_{\min\max}(X) = \frac{2.(X - X_{\min})}{(X_{\max} - X_{\min})} - 1 \quad \text{(IV.14)}$$

$$output_n = map_{\min\max}\left(\log\left(output\right)\right) \quad \text{(IV.15)}$$

Où $input_n$ est la valeur normalisée de l'entrée, X_{max} et X_{min} sont les valeurs maximale et minimale des entrées, X est la valeur vectorielle d'origine des entrées, $output_n$ est la valeur normalisée de la sortie.

Afin de trouver le modèle optimal, de nombreux réseaux de neurones artificiels avec un nombre différent de neurones dans la couche cachée, différentes fonctions d'activation et différents algorithmes d'apprentissage ont été examinés. Le réseau de neurones artificiels optimal (Fig. IV.22) possède 8 neurones et une fonction de transfert sigmoïde tangente dans la couche cachée et le « Levenberg-Marquardt » comme algorithme d'apprentissage.

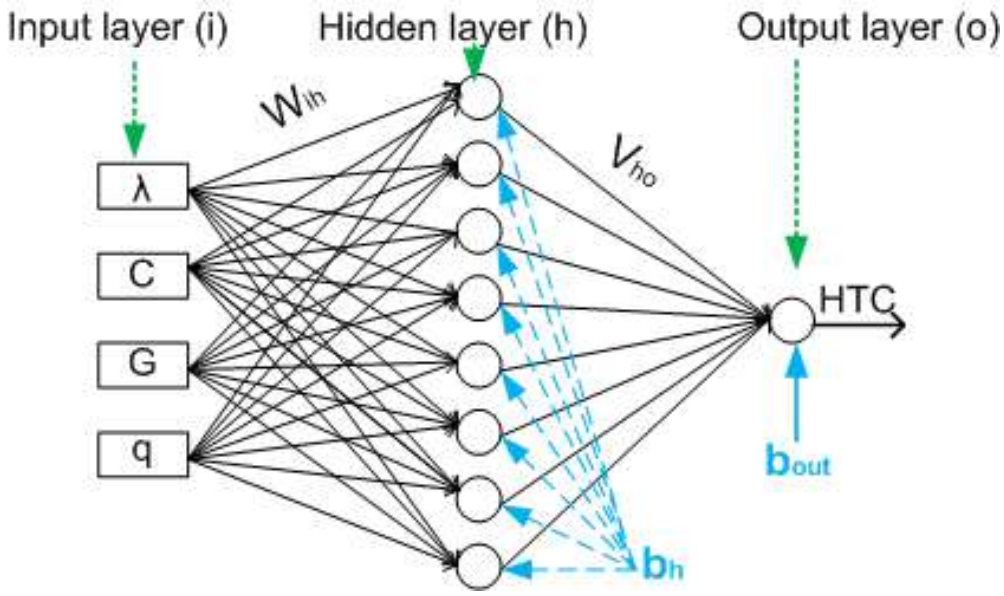


Figure IV.22. La plateforme d'architecture de l'ANN optimal

Le modèle de réseau de neurones artificiel développé qui relie la sortie normalisée aux entrées normalisées est donné par la formule suivante Eq. IV.16.

$$output_n = \sum_{j=1}^{j=N_h} \left[V_{ho} \cdot \left(\frac{2}{1+\exp\left(-2.\left(b_h + \sum_{i=1}^{i=N_p} W_{ih}.input_n \right) \right)} - 1 \right) \right] + b_{out}. \qquad \text{(IV.16)}$$

W_{ij} et V_j sont les poids synaptiques entre la couche d'entrée et la couche cachée, ainsi qu'entre la couche cachée et la couche de sortie successivement. b_j et b_{out} sont les vecteurs de biais de la couche cachée et de la couche de sortie.

IV.4.3. Critères de performance

Plusieurs critères de performance ont été utilisés pour évaluer le modèle intelligent développé. L'erreur absolue relative moyenne (MRAE), l'erreur quadratique moyenne (MSE), le coefficient de corrélation (R), le coefficient de détermination (R^2), le facteur de précision (A_f) et le facteur de biais (B_f) [160], l'indice de concordance de Wilmot (WI) et l'indice de Legates-McCabe Indice (IMT) [170] ont été utilisées comme mesure de la précision qui sont exprimées comme suit :

$$MRAE\,\% = \frac{100}{N}\sum_{1}^{N}\frac{\left|y^{\exp} - y^{cal}\right|}{y^{\exp}} \tag{IV.17}$$

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y^{\exp} - y^{cal})^2 \tag{IV.18}$$

$$R = \frac{\sum_{i=1}^{N}\left(y_i^{cal} - \overline{y^{cal}}\right)\left(y_i^{\exp} - \overline{y^{\exp}}\right)}{\sqrt{\sum_{i=1}^{N}\left(y_i^{cal} - \overline{y^{cal}}\right)^2\sum_{i=1}^{N}\left(y_i^{\exp} - \overline{y^{\exp}}\right)^2}} \tag{IV.19}$$

$$R^2 = 1 - \frac{\sum_{1}^{N}\left(y_i^{\exp} - y_i^{cal}\right)^2}{\sum_{1}^{N}\left(y_i^{\exp} - \overline{y_i^{\exp}}\right)^2} \tag{IV.20}$$

$$A_f = 10^{\left(\frac{1}{N}\sum_{1}^{N}\left|\log\frac{y_i^{cal}}{y_i^{\exp}}\right|\right)} \tag{IV.21}$$

$$B_f = 10^{\left(\frac{1}{N}\sum_{1}^{N}\log\frac{y_i^{cal}}{y_i^{\exp}}\right)} \tag{IV.22}$$

$$WI = 1 - \frac{\sum_{i=1}^{N}\left(y^{\exp} - y^{cal}\right)^2}{\sum_{i=1}^{N}\left(\left|y^{cal} - \overline{y^{\exp}}\right| + \left|y^{\exp} - \overline{y^{\exp}}\right|\right)^2} \tag{IV.23}$$

$$LMI = 1 - \frac{\sum_{i=1}^{N}\left|y^{\exp} - y^{cal}\right|}{\sum_{i=1}^{N}\left|y^{\exp} - \overline{y^{\exp}}\right|} \tag{IV.24}$$

IV.4.4. Résultats et discussions

Les critères comprenant MRAE, MSE, R, R^2, A_f, B_f, WI, LMI ont été calculés et présentés dans le tableau. IV.10. Les résultats obtenus ont montré que le modèle développé est capable de prédire le coefficient de transfert de chaleur d'ébullition d'écoulement de différents nanofluides à base d'eau dans un tube horizontal avec une haute précision. Les valeurs de WI, LMI, A_f et B_f sont proches de la valeur idéale (unité) et indiquent la qualité de la prédiction de HTC.

Tableau IV.10. Critères de performances du modèle RNA.

	Apprentissage	Test	Validation	Tous
MRAE%	0.99517	1.40568	1.20480	1.04827
MSE	0.00470	0.00007	0.66554	0.04198
R	0.99964	0.99923	0.99964	0.99961
R^2	0.99939	0.99847	0.99939	0.99922
A_f	1.01000	1.01413	1.01206	1.01053
B_f	0.99995	0.99936	1.00410	1.00034
WI	0.99999	0.99999	0.99997	0.99999
LMI	0.98154	0.96772	0.97113	0.98060

Le diagramme de régression du réseau de neurones artificiels pour les données d'apprentissage, de validation et de test est illustré à la Fig. IV.23. Les résultats valeurs de HTC prédites par le modèle ANN correspondent très bien aux valeurs expérimentales.

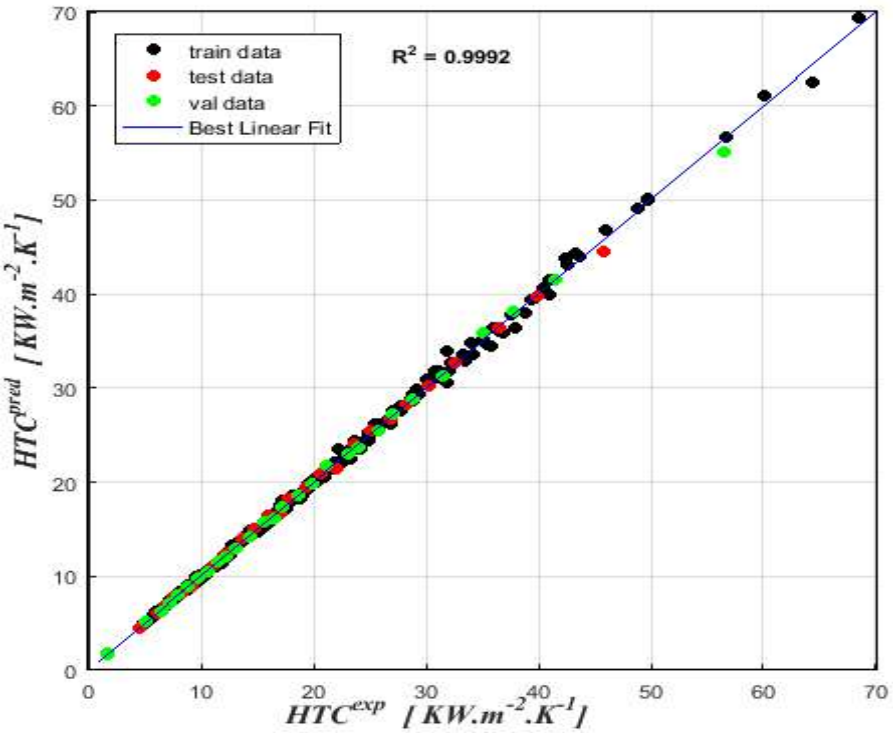


Figure IV.23. Diagramme de régression ANN

Le tracé des résidus des valeurs expérimentales de HTC dans les ensembles d'apprentissage, de test et de validation par rapport à leurs valeurs prédites a été déterminé et étudié dans la Fig. IV.24. Le modèle développé n'a pas montré d'erreur proportionnelle et systématique car la distribution des résidus des deux côtés de zéro était aléatoire.

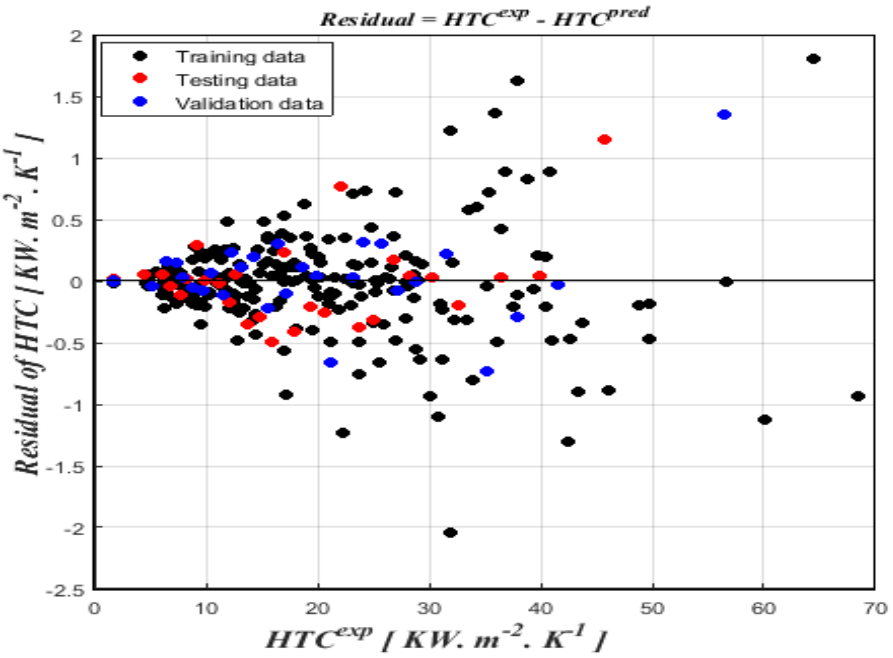


Figure IV.24. Les résidus versus leurs valeurs expérimentales

Les valeurs optimales des poids et des biais (W_{ih}, W_{ho}, b_h, b_{out}) de l'architecture ANN montrées dans la Fig. IV.22 ont été résumées dans le Tableau. IV.11. Ces valeurs de poids et de biais ont été utilisées dans le modèle intelligent proposé donné dans l'équation IV.16 pour la prédiction du coefficient de transfert de chaleur (HTC) lors de l'ébullition en écoulement de nanofluides à base d'eau dans un tube horizontal.

Tableau IV.11. Les valeurs optimales des poids et des biais du modèle ANN

h	Poids synaptiques entre la couche d'entrée et la couche cachée				Biais dans la couche cachée	Poids synaptiques entre la couche cachée et la couche de sortie	Biais dans la couche de sortie
	W_{1h}	W_{2h}	W_{3h}	W_{4h}	b_h	V_{ho}	b_{out}
1	0.0397	0.0391	-45.5188	0.8130	-46.6200	-5.0713	-5.2490
2	-0.4141	-0.5524	-0.3038	0.0786	0.6913	-0.7308	
3	0.2491	-1.3742	0.1924	0.2466	0.1412	-0.6252	
4	0.5934	-1.8905	-0.4738	0.0309	-0.3210	0.2994	
5	9.4881	2.2326	-2.1163	1.2850	-1.9802	-0.0260	
6	-1.0095	-8.7286	0.8245	1.0097	-8.9144	-8.1079	
7	3.7837	7.2702	-0.4797	-0.0393	-6.5949	-0.0829	
8	0.0240	0.0070	0.8188	1.0064	0.1946	8.1830	

IV.4.4.1. Effet de la conductivité thermique et de la concentration sur HTC

Les résultats obtenus à partir de la prédiction du modèle intelligent montrent que la conductivité thermique des nanoparticules et la concentration volumétrique ont une influence majeure sur le coefficient de transfert de chaleur d'ébullition en écoulement des nanofluides à base d'eau dans un tube horizontal.

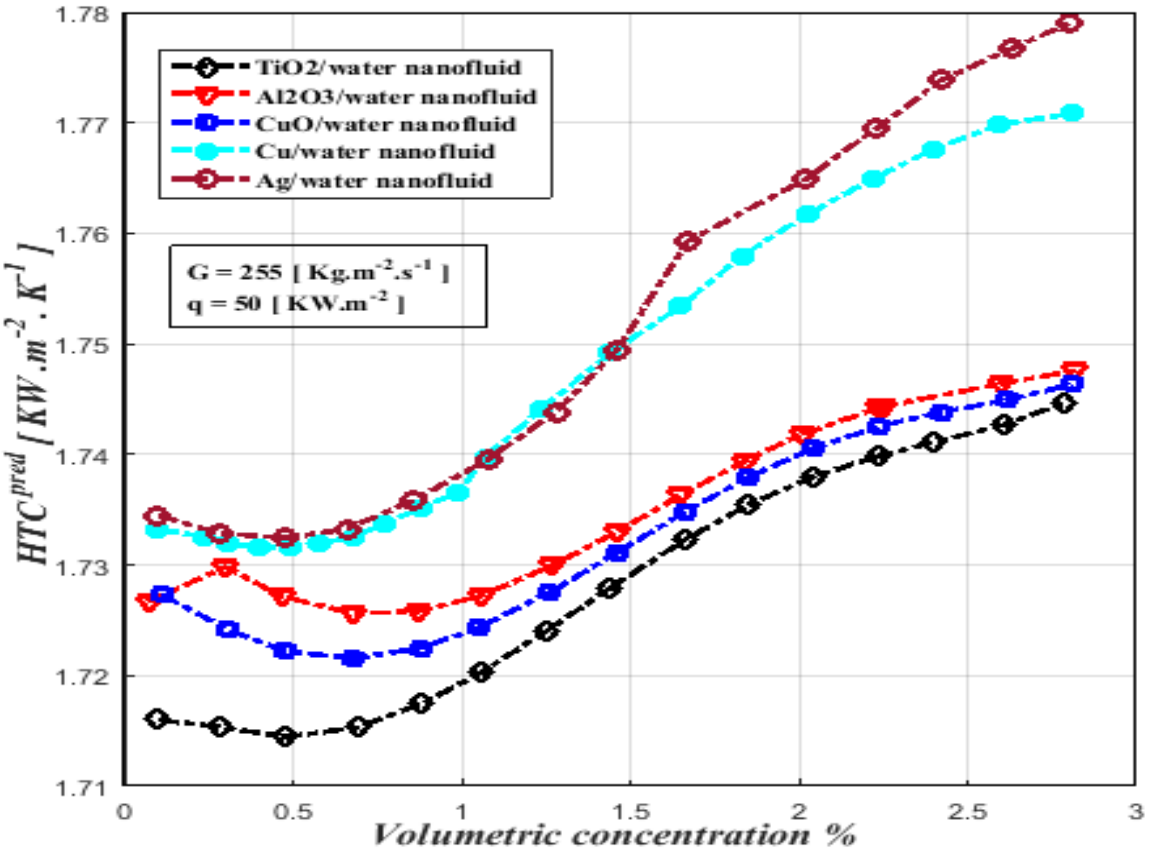


Figure IV.25. L'effet de la concentration volumétrique et l'effet de la conductivité thermique sur HTC

A partir de la Fig. IV.25, il est clair que le coefficient de transfert de chaleur augmente avec l'augmentation de la concentration volumétrique pour les différents nanofluides, Il est également clair que le HTC augmente avec une augmentation de la conductivité thermique des nanoparticules car le HTC prend des valeurs plus élevées pour Ag/eau et Cu/eau ($\lambda_{Ag} > \lambda_{Cu} > \lambda_{Al_2O_3} > \lambda_{CuO} > \lambda_{TiO_2}$).

IV.4.4.2. Effet de débit massique et flux de chaleur sur HTC

Les résultats présentés dans les Fig. IV.26.a et Fig. IV.26.b montrent que le HTC augmente avec une augmentation du flux de masse et avec une augmentation du flux de chaleur. Ces résultats sont similaires à ceux de Manish Dadhich et al. [124].

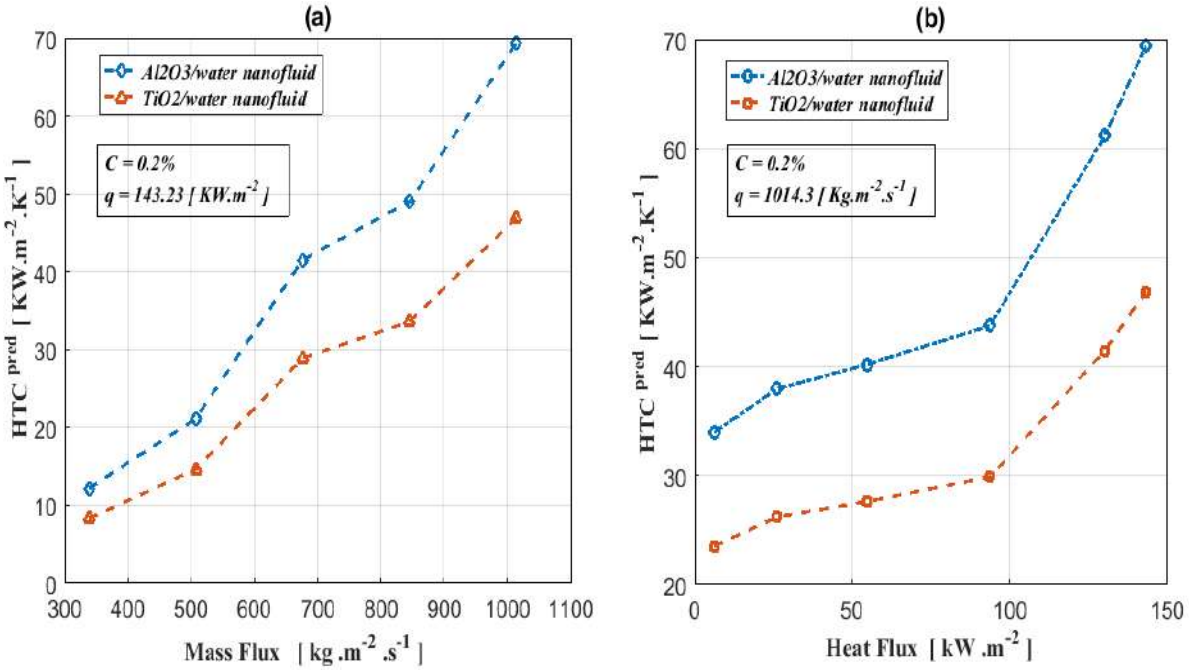


Figure IV.26. L'effet de débit massique et flux de chaleur sur HTC

IV.4.4.3. Performance du nanofluide

La performance du nanofluide est un paramètre qui caractérise l'amélioration du transfert de chaleur du nanofluide par rapport à l'eau pure [171]. L'équation suivante est considérée :

$$performance_du_nanofluide = \frac{HTC^{nanofluid} - HTC^{water}}{HTC^{water}}.100 \qquad \text{(IV.25)}$$

Où $HTC_{nanofluid}$ et HTC_{water} sont respectivement les coefficients de transfert de chaleur du nanofluide et de l'eau pure.

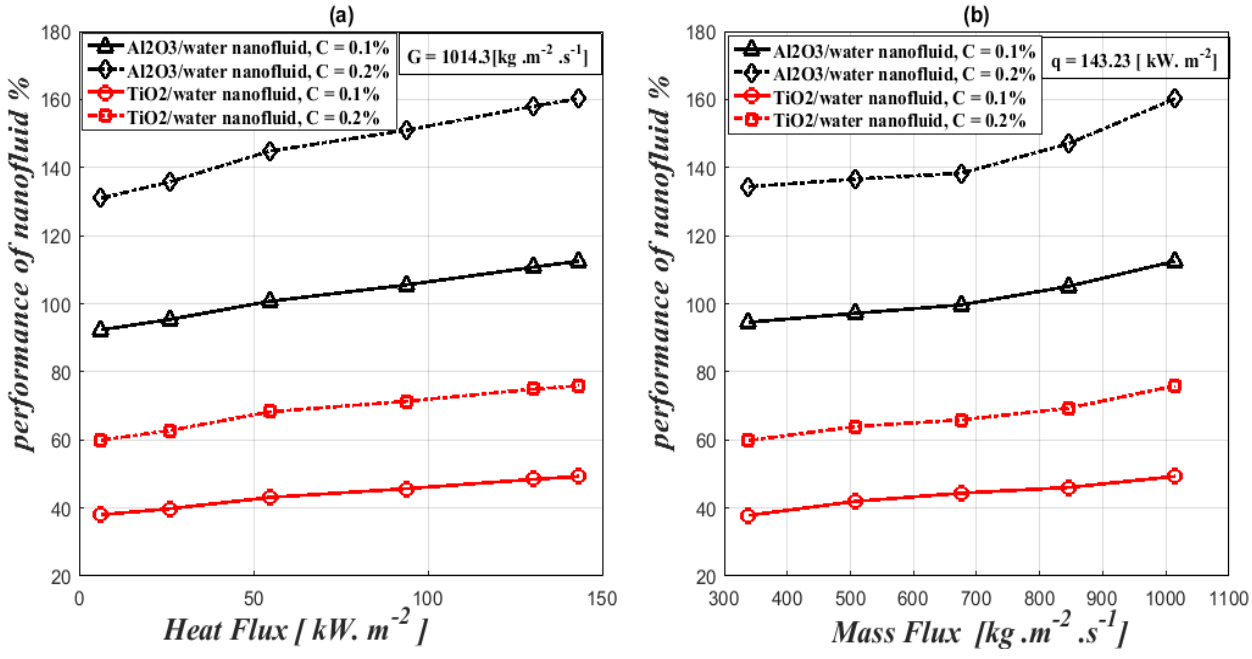


Figure IV.27. L'effet de débit massique et flux de chaleur sur HTC

Les figures IV.27.a et IV.27.b montrent que pour chaque concentration volumétrique, la nanoparticule Al_2O_3 améliore le coefficient de transfert de chaleur d'ébullition du flux d'eau pure mieux que la nanoparticule TiO_2 car la conductivité thermique de l'Al_2O_3 est supérieure à celle du TiO_2. A partir des figures, on observe que l'augmentation de HTC augmente avec une augmentation du débit massique, concentration volumétrique et flux de chaleur qui sont en accord avec les résultats rapportés dans la littérature [124, 172].

IV.4.4.4. Validation du modèle intelligent

En terme de coefficient de corrélation (R), le modèle développé a été comparé à d'autres modèles de réseaux de neurones artificiels pour la prédiction du coefficient de transfert de chaleur lors de l'ébullition des nanofluides Al_2O_3/eau et TiO_2/eau dans un tube horizontal [124]. La comparaison a été présentée dans le tableau IV.12, et elle confirme la précision et la généralité du modèle ANN.

Tableau IV.12. Comparaison avec d'autres ANN modèles

	Nombre de données	Nanofluides	Coefficient de corrélation *R*
Premier ANN modèle[124]	120	*Al_2O_3*/water	0.99905
Deuxième *ANN* modèle [124]	120	*TiO_2*/water	0.99930
Présent *ANN* model	354	*Al_2O_3*/water, *TiO_2*/water *Cu*/water *CuO*/water *Ag*/water	0.99961

Le modèle développé a été également comparé avec la corrélation empirique pour TiO_2/eau donnée dans l' Eq. (III.5) et avec la corrélation empirique pour Al_2O_3/eau donnée dans l' Eq. (III.6).

Le modèle intelligent a également été comparé aux données expérimentales de Dadhich et al. [124]. Cette comparaison a été présentée dans la Fig. IV.28. Les résultats observés sur la Fig. IV.28 montrent la validité et la précision du réseau de neurones artificiels développé pour la prédiction du coefficient de transfert de chaleur d'ébullition de flux de nanofluides à base d'eau dans un tube horizontal par rapport aux corrélations empiriques.

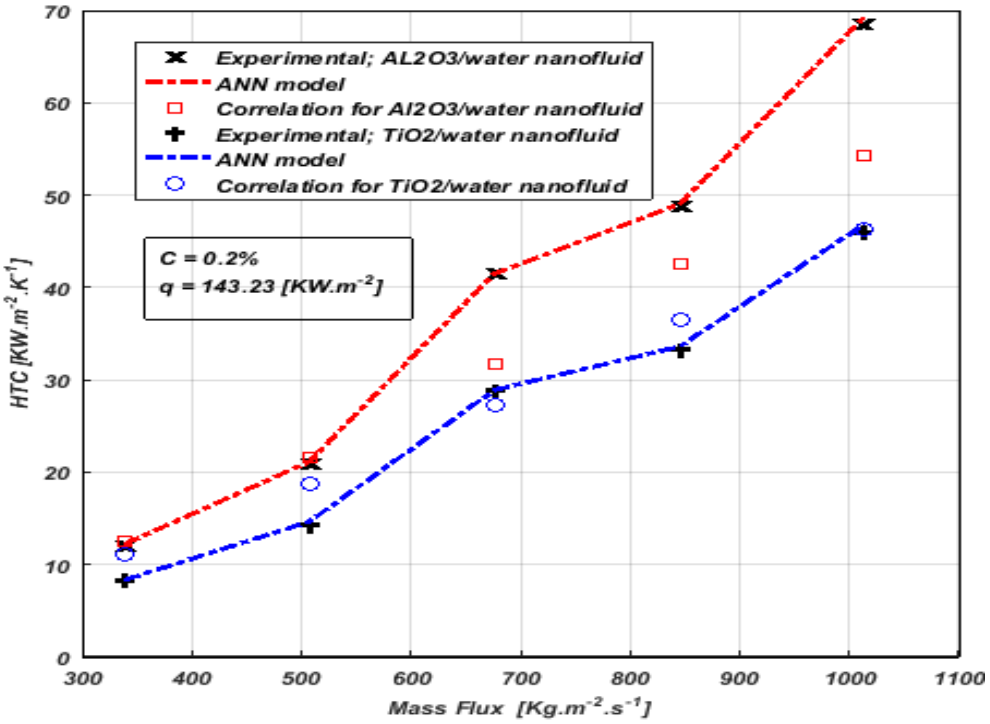


Figure IV.28. Comparaison du modèle ANN avec les corrélations empiriques et avec les données expérimentales

IV.4.4.5. Analyse de sensibilité

Il existe de nombreuses méthodes qui permettent de déterminer la contribution de toutes les variables d'entrée (concentration volumétrique, flux de chaleur, débit massique, conductivité thermique de la nanoparticule) sur la sortie (HTC).

Dans cette étude, une méthode basée sur le partitionnement des poids de connexion proposée par Garson [163] est utilisée. Il a également été appliqué par Goh [173]. L'importance relative des variables d'entrée sur la variable de sortie (RI) est exprimée comme suit :

$$RI\% = \frac{\sum_{h=1}^{N_h}\left(\left(\left|W_j\right| / \sum_{i=1}^{N_p}\left|W_{ih}\right|\right).\left|V_{ho}\right|\right)}{\sum_{i=1}^{N_p}\left\{\sum_{h=1}^{N_h}\left(\left(\left|W_j\right| / \sum_{i=1}^{N_p}\left|W_{ih}\right|\right).\left|V_{ho}\right|\right)\right\}}.100 \qquad \text{(IV.26)}$$

Dans cette équation, N_p et N_h représentent respectivement le nombre de neurones dans la couche cachée et la couche d'entrée. Le W_{ih} est la valeur absolue des poids synaptiques entre la couche d'entrée et la couche cachée. V_{ho} est la valeur absolue des poids synaptiques entre la couche cachée et la couche de sortie.

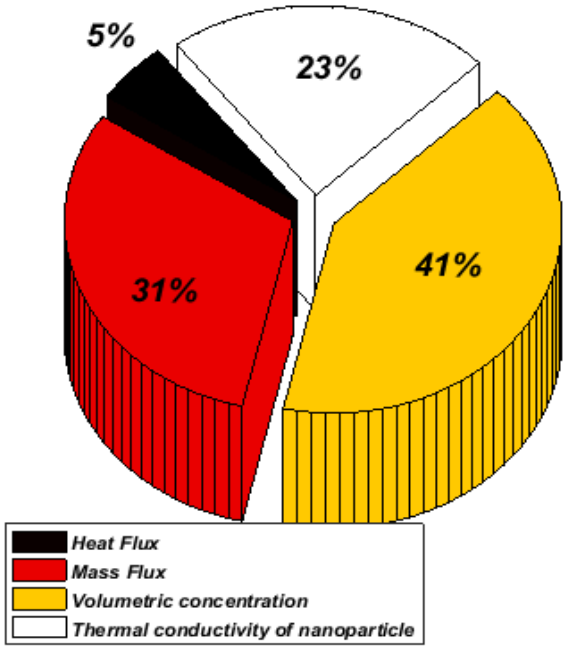


Figure IV.29. Effet des variables d'entrée sur HTC

Comme le montre la figure IV.29, la concentration volumétrique a un effet majeur sur le HTC (41 %), le coefficient de transfert de chaleur augmente avec une augmentation de la faible concentration volumétrique. Le flux massique a un effet de 31% sur HTC, lorsque le flux massique augmente, la taille moyenne des bulles diminue et quittent la surface chauffante en très peu de temps, ce qui entraîne une amélioration du transfert de chaleur, ce qui est en accord avec les résultats rapportés dans la littérature [124].

La conductivité thermique a un effet de 23% sur le coefficient de transfert de chaleur car les propriétés thermos-physiques des nanoparticules améliorent les phénomènes de transfert de chaleur, le flux de chaleur a un faible effet sur le HTC (5%).

IV.4.5. Conclusion

L'étude vise principalement à développer un modèle intelligent précis pour la prédiction du coefficient de transfert de chaleur lors de l'ébullition en écoulement de nanofluides à base d'eau dans un tube horizontal en utilisant la technique du réseau de neurones artificiels.

Après l'examen d'un nombre important de réseaux de neurones différemment structurés, la structure de réseau de neurones artificiel adéquate qui a été sélectionnée dans cette enquête a une seule couche cachée avec 8 neurones. La fonction de transfert dans la couche cachée était la tangente sigmoïde et la fonction de transfert linéaire dans la couche de sortie. Les valeurs du coefficient de

transfert de chaleur qui ont été prédites à partir du modèle ANN développé ont été comparées aux valeurs expérimentales et aux valeurs obtenues à partir des corrélations empiriques. Les observations suivantes ont été déduites :

Les résultats prédits par le modèle ANN développé sont en meilleur accord avec les résultats expérimentaux par rapport aux résultats prédits par les corrélations empiriques.

Les résultats ont montré que l'augmentation de la conductivité thermique des nanoparticules conduit à une augmentation significative du coefficient de transfert de chaleur d'ébullition en flux des nanofluides.

L'amélioration du HTC des nanofluides augmente avec une augmentation du débit massique, de la concentration volumétrique et du flux de chaleur.

Sur la base des données expérimentales recueillies dans cette étude, il est possible de développer une corrélation empirique pour le calcul du coefficient de transfert de chaleur d'ébullition des nanofluides à l'aide de l'optimisation GWO (Gray Wolf Optimisation).

IV.5. Modélisation de l'ébullition des nanofluides par SVM

IV.5.1. Introduction

La méthodologie de régression à vecteurs de support (SVR) est meilleure dans la généralisation que la méthode du réseau neuronal artificiel (RNA) [174], Pour cette raison dans ce travail, nous avons utilisé les données expérimentales de Manish Dadhich et al. [124] pour développer des modèles de machine à vecteurs de support pour la prédiction du coefficient de transfert de chaleur des écoulements en ébullition des nanofluides TiO_2 /eau et Al_2O_3/eau dans un tube horizontale.

IV.5.2. Description du modèle SVR

La machine de vecteur de support (SVM) est une famille d'algorithmes d'apprentissage qui résolvent des problèmes de classification et de régression, ils sont connus pour leurs garanties théoriques solides, leur grande flexibilité et leur facilité d'utilisation, ils sont premièrement identifiés par Vladimir Vapnik et ses collègues [175]. Le modèle de régression à vecteurs de support (SVR) transforme l'espace d'entrée en espace à hautes dimensions afin d'optimiser les limites de généralisation de la régression. L'algorithme SVR cherche à trouver une fonction qui approche la valeur de réponse prédite à la valeur de réponse observée avec une valeur epsilon (ε) de précision [175].

Considérez les données d'apprentissage (x_i, y_i) pour i = 1,… n, Où x_i est le vecteur de variables explicatives, y_i est la valeur définie de la variable de réponse. Dans le cas d'une fonction linéaire, la formulation SVR peut être donnée par EQ. (IV.27).

$$g(x,\omega) = \omega.x + b \tag{IV.27}$$

Où $g(x,\omega)$représente la fonction de régression à développer, ω représente le facteur de poids, b est le biais. L'estimation est évaluée par une fonction de perte insensible donnée dans EQ. (4).

$$L_\varepsilon\left(y, g(x,\omega)\right) = \max\left(\left|y - g(x,\omega)\right| - \varepsilon, 0\right) \tag{IV.28}.$$

La fonction de risque régularisé est minimisée par la formule donnée dans Eq. (5)

$$\min.R\left(\omega, \xi_i^*\right) = \frac{1}{2}\|\omega\|^2 + C\sum_{i=1}^{n}\left(\xi_i - \xi_i^*\right) \tag{IV.29}$$

$$\begin{cases} y_i - \omega.x_i - b \le \varepsilon + \xi_i \\ \omega.x_i + b - y_i \le \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \ge 0 \end{cases} \tag{IV.30}$$

Lorsque C est appelé la constante de régularisation, elle représente le compromis entre le risque empirique et la planéité du modèle, ξ_i, ξ_i^* sont appelés variables de relâchement, ce sont des quantités locales qui détendent la condition rigide de la séparabilité linéaire, où chaque point d'entraînement constate le même hyperplan marginal.

Application de fonction du noyau transforme ce problème d'optimisation au double problème donné dans l'équation (IV.31).

$$\left\langle \varphi(x_i), \varphi(x) \right\rangle = K(x_i, x) \tag{IV.31}$$

Ce problème d'optimisation est résolu par EQ. (IV.32)

$$g(x) = \sum_{i=1}^{T} \left(\alpha_i - \alpha_i^* \right) K\left(x_i, x \right) \tag{IV.32}$$

$$\begin{cases} 0 \le \alpha_i^* \le C \\ 0 \le \alpha_i \le C \end{cases} \tag{IV.33}$$

Où T est le nombre de vecteur de support, k (xi, x) est la fonction de noyau. Les différentes fonctions du noyau sont la fonction de noyau à base radiale (RBF) définie dans Eq. (IV.34), la fonction de noyau polynomiale définie dans Eq. (IV.35), la fonction de noyau linéaire définie dans Eq. (IV.36).

$$K\left(x_i, x_j \right) = e^{\left(\frac{-1}{2\sigma^2} \left\| x_i - x_j \right\|^2 \right)} \tag{IV.34}$$

$$K\left(x_i, x_j \right) = \left(x_i^T . x_j + 1 \right)^d \tag{IV.35}$$

$$K\left(x_i, x_j \right) = x_j^T x_i \tag{IV.36}$$

La prédiction du coefficient de transfert de chaleur (HTC) d'un écoulement en ébullition des nanofluides dans un tube horizontal par expérience est très coûteuse. L'objectif de ce travail est de trouver un modèle précis peut être prédire le coefficient de transfert de chaleur d'un écoulement en ébullition des nanofluides Al_2O_3/H_2O et TiO_2/H_2O dans un tube horizontale. Les données expérimentales sont collectées à partir des travaux de Manish Dadhich et al. [124], nous allons choisir l'approche SVM car il a une meilleure généralisation avec une base de données limitée par rapport à l'approche du réseau de neurones.

La gamme de variables pour les nanofluides Al_2O_3/H_2O et TiO_2/ H_2O est présentées dans le tableau IV.13 et IV.14, respectivement.

Tableau IV.13. Gamme variables pour Al_2O_3/H_2O nanofluide, P = 1bar

	Variables	Mesure	Unités	Min	Max
Entrée	-concentration volumétrique	C%	/	0.05	0.2
	-Débit massique	G	[kg/m^{2}s]	338.13	1014.4
	-Flux de chaleur	q	[KW/m^2]	6.25	143.23
Sortie	Coefficient de transfert de chaleur	HTC	kW/m^{2}K	7.29	68.44

Tableau IV.14. Gamme variables pour TiO_2/H_2O nanofluide, P = 1bar

	Variables	Mesure	Unités	Min	Max
Input	- concentration volumétrique	C%	/	0.05	0.2
	-Débit massique	G	[kg/m^{2}s]	338.13	1014.4
	-flux de chaleur	q	[KW/m^2]	6.25	143.23
Output	Coefficient de transfert de chaleur	HTC	kW/m^{2}K	5.59	46

Les deux modèles SVR optimaux sont obtenus à travers le processus illustré à la figure IV.30.

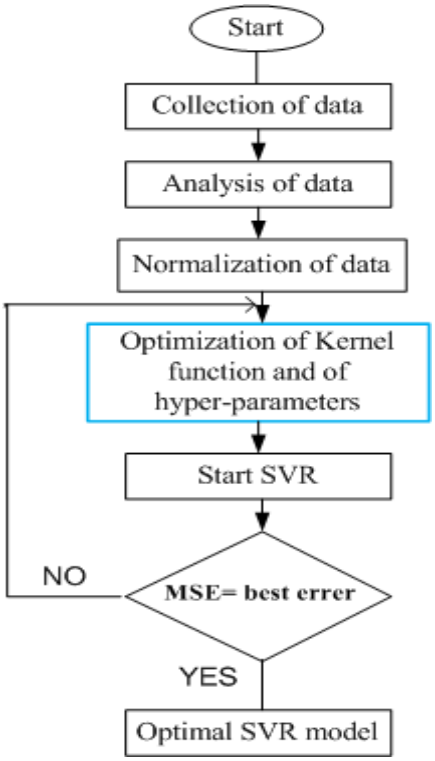


Figure IV.30. Organigramme du processus d'optimisation des modèles SVR

IV.5.3. Evaluation du modèle SVR

Dans ce travail, nous avons utilisé plusieurs critères de performance pour évaluer les deux modèles SVR développés tels que l'erreur carrée moyenne (MSE), l'erreur absolue relative moyenne (MRAE), le coefficient de corrélation (R), le coefficient de détermination (R^2), Indice de Wilmot (WI) et l'indice de Legates-McCabe (LMI) et le facteur de précision (A_F) [176].

IV.5.4. Résultats et discussions

Dans ce travail, nous avons examiné plusieurs fonctions de noyau pour développer les deux modèle SVR tels que la fonction de noyau linéaire, la fonction de noyau Gaussien, la fonction de noyau RBF et la fonction de noyau polynomiale. Tableau. IV.15 et Tableau. IV.16 montrent les performances statistiques des deux modèles SVR développés avec les différentes fonctions de noyau. Les résultats des deux modèles SVR montrent que la fonction de base radiale (RBF) avec les paramètres optimisés donne les meilleures prédictions. Les valeurs de la MRAE ont confirmé la précision du modèle, les valeurs de R et R^2 indiquaient la fiabilité et la pertinence des modèles SVR. Les valeurs de A_f sont proches de l'unité et ont indiqué la validité des modèles proposées, Les valeurs de WI et LMI proches de la valeur idéale (unité) et indiquent la bonne prédiction de HTC.

Tableau IV.15. SVR-Model avec differents fonctions de noyau pour TiO_2/water nanofluide

	Hyper paramètres			Critères statistiques						
	C	ζ	γ	*MSE*	*MRAE*	*R*	R^2	*WI*	*LMI*	A_f
Linéaire	22.4	0.81		2.23	11.23	0.8247	0.6478	1.1401	0.8947	1.2210
RBF	52	0.1	0.001	0.10	0.8319	09999	0.9998	1.0009	0.9854	1.0083
Polynomiale	2	0.15		1.67	4.1122	0.9654	0.9547	1.0076	0.9014	1.0459
Gaussien	197	0.2	0.01	0. 24	3.8476	0.9876	0.9747	1.0018	0.9126	1.0389

Tableau IV.16. SVR-Modèle avec différents fonctions de noyau pour AL_2O_3/water nanofluide

	Hyper paramètres			Critères statistiques						
	C	ζ	γ	*MSE*	*MRAE*	*R*	R^2	*WI*	*LMI*	A_f
Linéaire	37.1	0.97		4.47	13.61	0.8145	0.6387	1.1525	0.8847	1.2325
RBF	187	0.3	0.001	0.50	1.93	09998	0.9995	1.0008	0.9731	1.0193
Polynomiale	1	0.22		2.54	6.01	0.9541	0.9341	1.0144	0.8974	1.0547
Gaussien	115	0.74	0.002	0.87	5.32	0.9929	0.9846	0.9999	0.9109	1.0548

Afin d'évaluer la capacité prédictive des modèles SVR optimisés. La figure. IV.31 représente les données prédites par modèle SVR pour les nanofluide TiO_2/eau par rapport aux données expérimentales pour la phase d'apprentissage et la phase de test. La figure IV.32 illustre les données prédites par modèle SVR pour les nanofluide Al_2O_3/eau par rapport aux données expérimentales. Les résultats montrent la précision des modèles SVR développés pour la prédiction de coefficient de transfert de chaleur HTC.

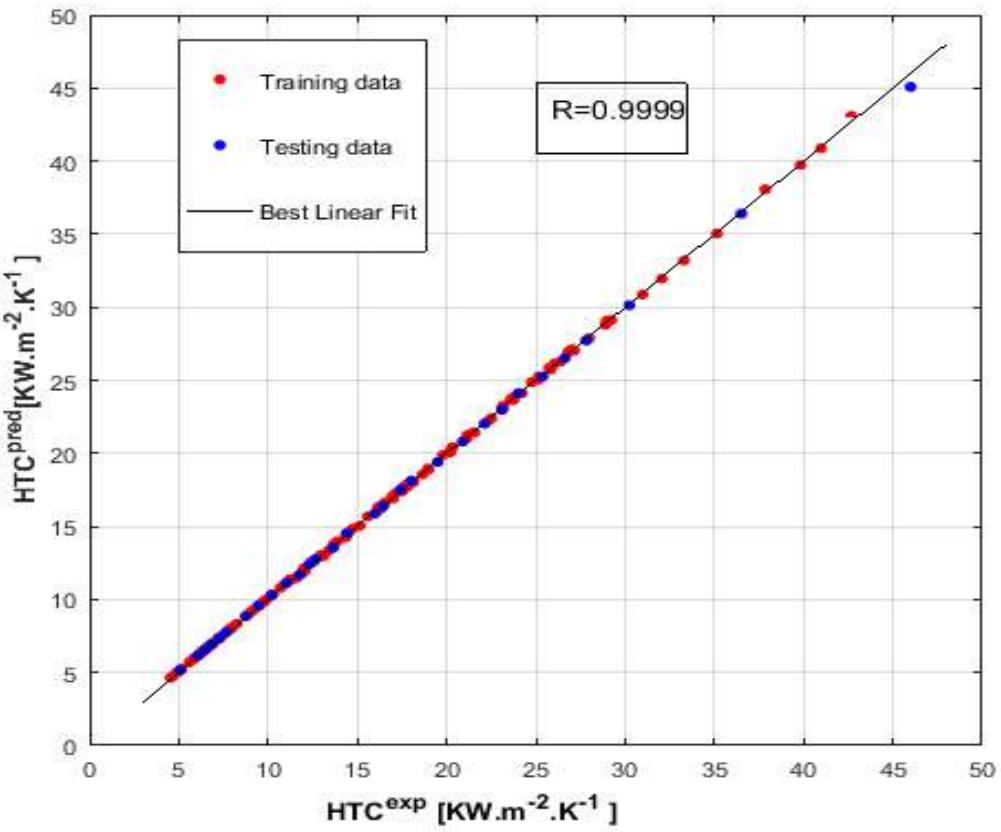


Figure IV.31. Graphe de régression du SVR modèle pour TiO_2 / eau nanofluide

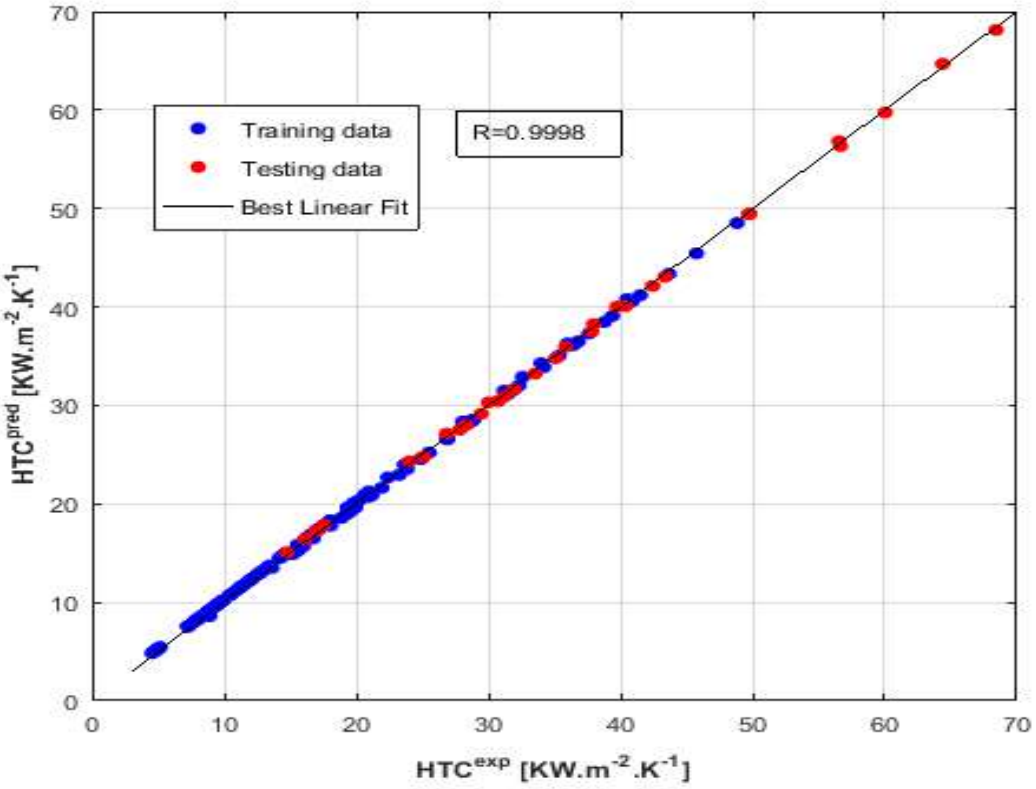


Figure IV.32. Graphe de régression du SVR modèle pour Al_2O_3/ eau nanofluide

La figure IV. 33 et la fig. IV. 34 décrivent le bon accord entre les valeurs expérimentales de coefficient de transfert de chaleur et les valeurs prédites par le modèle SVR-RBF pour le nanofluide TiO_2 /eau et nanofluide Al_2O_3/eau respectivement.

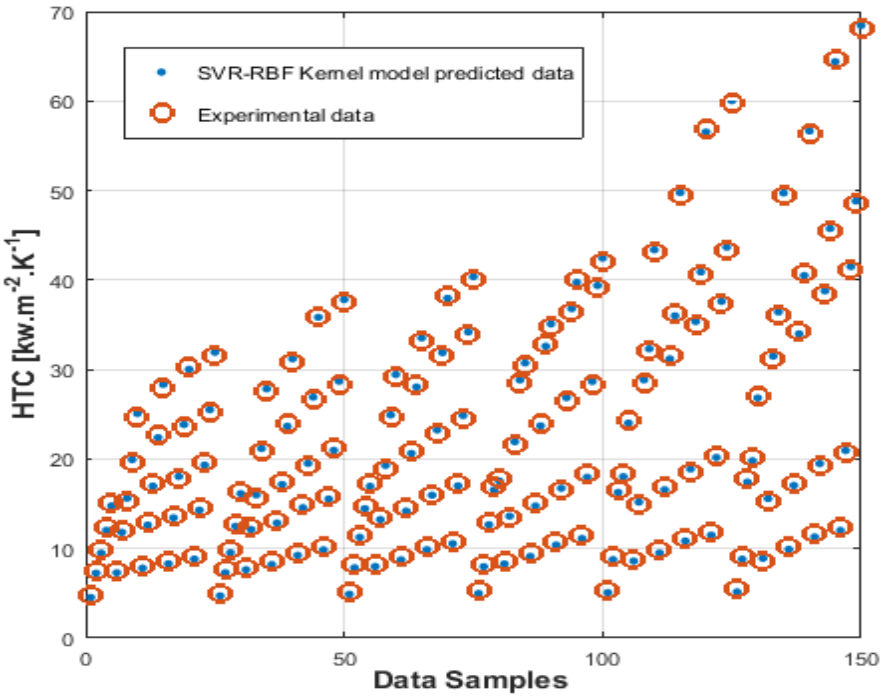


Figure IV. 33. Comparaison entre les prédictions SVR-RBF modèle pour TiO_2/ eau nanofluide et les données expérimentales

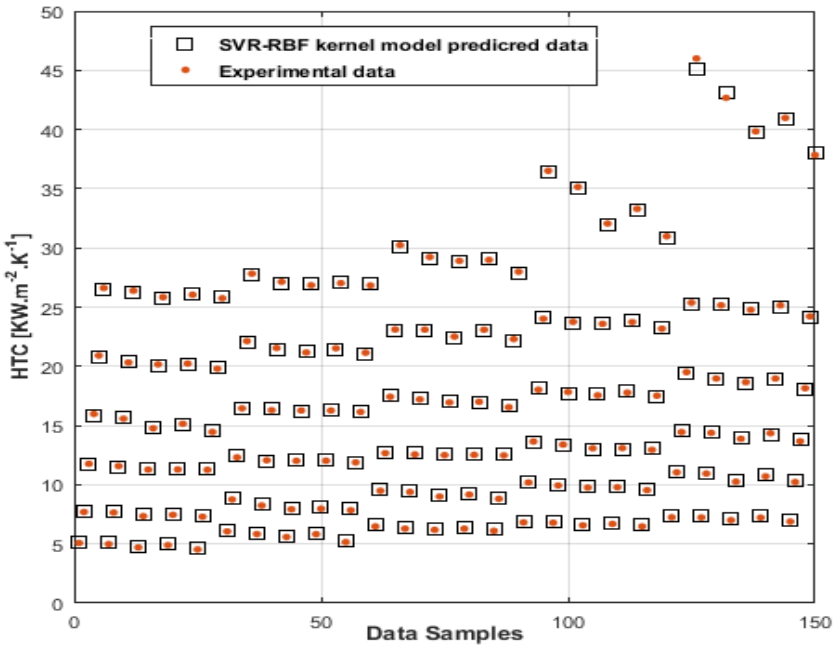


Figure IV.34. Comparaison entre les prédictions SVR-RBF modèle pour Al_2O_3/ eau nanofluide et les données expérimentales

Pour valider les deux modèles SVR-RBF développées, nous les avons comparés avec les corrélations empiriques de HTC d'un écoulement en ébullition des nanofluides TiO_2/eau et Al_2O_3/ eau dans un tube horizontale, la comparaison est présentée dans lla figure. IV.35 et la figure IV. 36 respectivement et montre la validité des deux modèles développées pour la prédiction du coefficient de transfert de chaleur (HTC) des écoulement en ébullition des nanofluides TiO_2/ eau et Al_2O_3/ eau dans un tube horizontale.

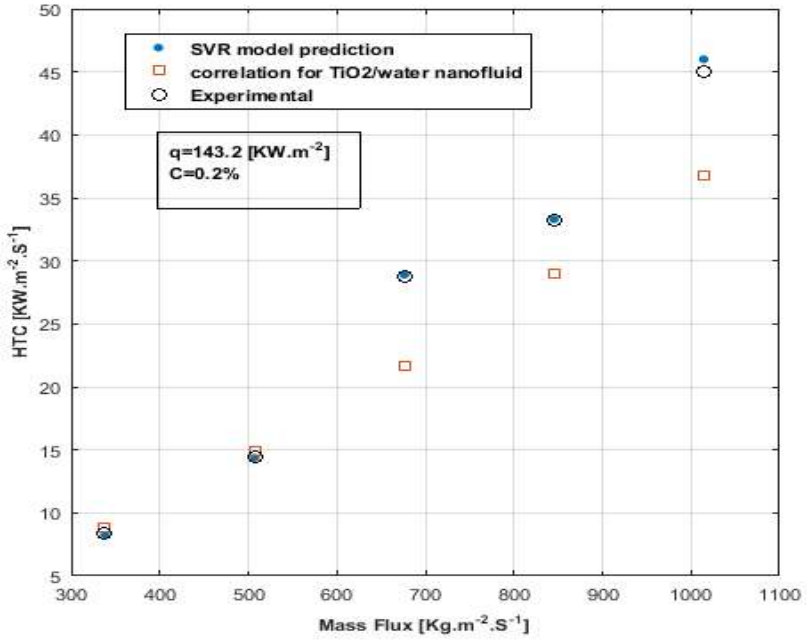


Figure IV.35. Comparaison entre les prédictions SVR-RBF modèle pour Al_2O_3/eau nanofluide et la corrélation empirique de Gong et al

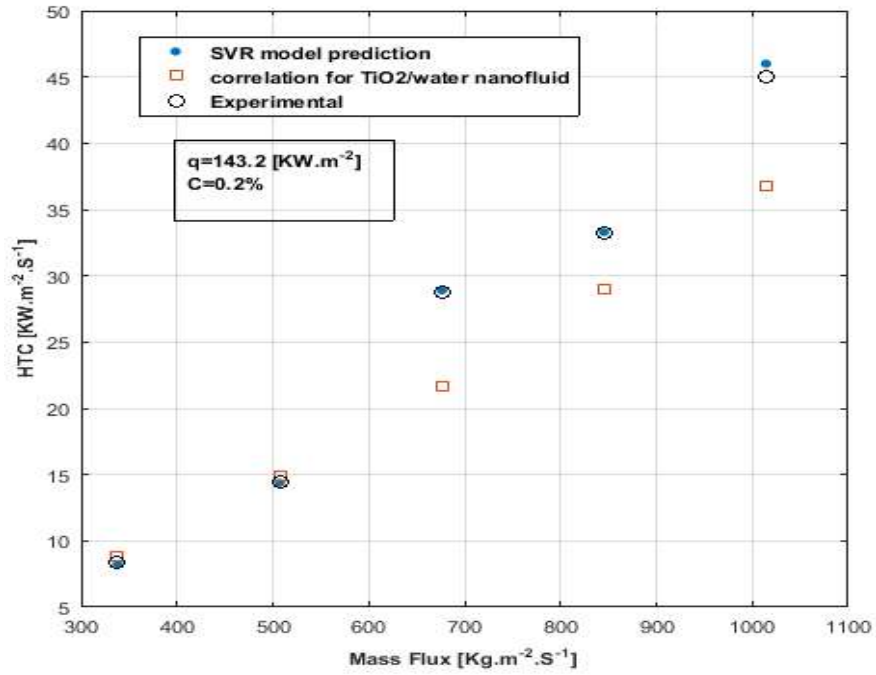


Figure IV.36. Comparaison entre les prédictions SVR-RBF modèle pour TiO_2/eau nanofluide et la corrélation empirique de Gong et al

IV.5.5. Conclusion

Dans ce travail, deux modèles de régression à vecteur de support (SVR) ont été développés dans le but de prédire le coefficient de transfert de chaleur (HTC) pour l'ébullition en écoulement des nanofluides TiO_2/Eau et Al_2O_3/Eau dans un tube horizontale.

Chaque modèle a été conçu et entraîné à l'aide de 120 données expérimentales collectées à partir de la littérature, pour les deux modèles, la concentration volumétrique, le débit massique et le flux thermique sont les variables d'entrée, tandis que le HTC est la variable de sortie.

Dans les deux modèles, les valeurs prédites de HTC et les valeurs expérimentales montrent un bon accord. La valeur d'erreur quadratique moyenne (MSE) pour toutes les données est de 0,12 et 0,13 pour les nanofluides TiO_2 et Al_2O_3 respectivement, les valeurs du coefficient de corrélation (R) sont de 0,990 et 0,991 respectivement. La comparaison des modèles développés (SVR) avec des corrélations empiriques montre une bonne performance.

Conclusion générale

Conclusion générale

Depuis quelques années, l'Intelligence Artificielle (IA) connaît un regain d'intérêt sans précédent grâce à d'importantes avancées technologiques, notamment dans le domaine de l'apprentissage machine (machine learning), qui étendent les capacités des ordinateurs et accroissent leurs performances dans un grand nombre de domaines (traitement du langage, compréhension de la parole, reconnaissance d'images, robotique, modélisation des phénomènes complexe, …). L'ébullition est la forme la plus efficace de transfert de chaleur, mais elle reste la forme la plus complexe et la moins comprise. Par conséquent, dans ce travail de thèse, nous avons appliqué les techniques d'intelligence artificielle (RNA, SVM) pour prédire le coefficient de transfert de chaleur des écoulements en ébullition. Ce travail contient quatre contributions à la modélisation de l'ébullition.

Dans la première contribution, nous avons élaboré un modèle basé sur les réseaux de neurones artificielle pour la prédiction du coefficient de transfert de chaleur lors de l'ébullition de l'eau dans un canal incliné, en fonction de l'orientation, du flux de chaleur, de la faible qualité d'équilibre et du faible flux de masse. La comparaison entre les données expérimentales et les données prédites par le réseau de neurones montre les performances de l'architecture de réseau utilisée. Le modèle optimale a été obtenu avec la structure 4-30-1 en tenant compte de l'algorithme d'apprentissage de rétro-propagation de Levenberg-Marquardt et de la fonction de transfert tangente sigmoïde dans la couche cachée et de la fonction de transfert linéaire dans la couche de sortie. Un total de 520 points de données expérimentales a été collecté à partir de la littérature afin d'utiliser dans le modèle ANN comme points de données d'apprentissage, de validation et de test. Une erreur absolue relative moyenne (MRAE) de 0,68 % et un coefficient de corrélation (R) de 0,9997 ont été obtenus par le modèle ANN pour tous les ensembles de données. Nous concluons que l'effet d'orientation sur HTC est très important dans la région entre 30º et 70º, nous concluons également que les effets de débit massique et de qualité sur HTC sont faibles. La validité du modèle ANN est démontrée dans sa comparaison avec certaines corrélations empiriques pour le canal vertical et avec les résultats expérimentaux pour diverses orientations.

Dans la deuxième contribution nous avons développé un modèle neuronal de prédiction du coefficient de transfert thermique d'un écoulement en ébullition en film dans un tube vertical de 8 mm de diamètre, en fonction du flux de chaleur, du débit massique, de la qualité d'équilibre et de la pression. La comparaison entre les données expérimentales et les données prédites par le réseau de neurones montre les performances de l'architecture de réseau utilisée.

Le modèle ANN avec deux couches cachées et formé par l'algorithme trainlm a été utilisée pour la prédiction du coefficient de transfert de chaleur. 20 000 points de données ont été collectés à partir de la littérature pour être utilisés dans le modèle ANN comme points de données de l'apprentissage, de validation et de test. La comparaison entre les valeurs de coefficient de transfert de chaleur calculé par le modèle RNA développé et les valeurs expérimentales a montré un bon accord.

La troisième contribution vise principalement à développer un modèle intelligent précis pour la prédiction du coefficient de transfert de chaleur lors de l'ébullition en écoulement de nanofluides à base d'eau dans un tube horizontal en utilisant la technique du réseau de neurones artificiels.

Après l'examen d'un nombre important de réseaux de neurones différemment structurés, la structure de réseau de neurones artificiel adéquate qui a été sélectionnée dans cette enquête a une seule couche cachée avec 8 neurones. La fonction de transfert dans la couche cachée était le tangent sigmoïde et la fonction de transfert linéaire dans la couche de sortie. Les valeurs du coefficient de transfert de chaleur qui ont été prédites à partir du modèle ANN développé ont été comparées aux valeurs expérimentales et aux valeurs obtenues à partir des corrélations empiriques. Les observations suivantes ont été déduites :

Les résultats prédits par le modèle ANN développé sont en meilleur accord avec les résultats expérimentaux par rapport aux résultats prédits par les corrélations empiriques.

Les résultats ont montré que l'augmentation de la conductivité thermique des nanoparticules conduit à une augmentation significative du coefficient de transfert de chaleur d'ébullition en flux des nanofluides.

L'amélioration du HTC des nanofluides augmente avec une augmentation du débit massique, de la concentration volumétrique et du flux de chaleur.

Dans la dernière contribution, deux modèles de régression à vecteur de support (SVR) ont été développés dans le but de prédire le coefficient de transfert de chaleur (HTC) pour l'ébullition en écoulement des nanofluides TiO_2/Eau et Al_2O_3 /Eau dans un tube horizontale.

Chaque modèle a été conçu et entraîné à l'aide de 120 données expérimentales collectées à partir de la littérature, pour les deux modèles, la concentration volumétrique, le débit massique et le flux thermique sont les variables d'entrée, tandis que le HTC est la variable de sortie.

Dans les deux modèles, les valeurs prédites de HTC et les valeurs expérimentales montrent un bon accord. La valeur d'erreur quadratique moyenne (MSE) pour toutes les données est de 0,12 et 0,13 pour les nanofluides TiO_2 et Al_2O_3 respectivement, les valeurs du coefficient de corrélation (R) sont

de 0,990 et 0,991 respectivement. La comparaison des modèles développés (SVR) avec des corrélations empiriques montre une bonne performance.

Sur la base des données expérimentales recueillies dans cette thèse, il est possible de développer des corrélations empiriques pour le calcul du coefficient de transfert des écoulements en ébullition des fluides et des nanofluides à l'aide de l'optimisation GWO (Gray Wolf Optimisation).

Références bibliographiques

[1]. John, G, et al., Convective boiling and condensation, International Book Company, Third Edition. 2001.

[2]. Alves, G. Co-current liquid gas flow in a pipeline contactor, Chem. Eng. Progress, 50, pp. 449-456. 1954

[3]. Collier, J, et al., Convective boiling and condensation. s.l. : Oxford Science Publications, 1994.

[4]. Ferrouk, M. Contribution à l'étude de la crise d'ébullition à faible titre. Thèse de doctorat. Boumerdes, Université M'hamed Bougara. Faculté des hydrocarbures et de la chimie. 2009.

[5]. Stephen, U, et al,.Enhancing thermal conductivity of fluids with nanoparticles. International mechanical engineering congress and exhibition.1995

[6]. Olivier, D, et al., Une nouvelle technologie pour les échangeurs thermiques, Le Nanofluide.2007

[7]. Kim, S., et al., Experimental investigation of critical heat flux enhancement by micro/nanoscale surface modification in pool boiling'. Proceedings of the Sixth International ASME Conference on Nanochannels, Microchannels and Minichannels ICNMM2008, Darmstadt, (2008).

[8]. Truong, B., et al., Surface modifications using nanofluids for nucleate boiling heat transfer and CHF enhancements'. Proceedings of the Sixth International ASME Conference on Nanochannels, Microchannels and Minichannels ICNMM2008, Darmstadt, (2008).

[9]. Cichelli, M, et al., Heat Transfer to Liquids Boiling Under Pressure, Trans. AIChE, Vol. 41, pp. 411-412.2009.

[10]. Berenson, P, et al., Transition boiling heat transfer from a horizontal surface. Sc.D. Thesis, Mech. Eng. Dept., MIT Tech. Report No. 17, 1960.

[11]. Delhaye, M, Thermohydraulique des réacteurs. s.l. : Collection génie atomique, EDP Sciences, 2008.

[12]. Thibault, E, et al., Cycles thermodynamiques des machines thermiques. s.l. : Institut National Polytechnique de Grenoble, 2006.

[13]. Lallemand, M, Transferts en changement de phase Ébullition libre, technique de l'ingénieur, BE 8 235, 2007.

[14]. Zhu, Y, Numerical Investigation of the Flow and Heat Transfer within the Core Cooling Channel of a Supercritical Water Reactor. s.l. : IKE, Université de Stuttgart, 2010.

[15]. Faccanoni, G. Etude d'un modèle fin de changement de phase liquide-vapeur : Contribution à l'étude de la crise d'ébullition. s.l. : Ecole polytechnique, Univeristé de Trento et CEA, Thèse de Doctorat, 2008.

[16]. Mohammedi, B, Simulation de l'établissement de l'ébullition nucléée par l'approche CFD: Univeristé de Medea, Thèse de Doctorat, 2016.

[17]. Pioro, W, et al., Nucleate pool-boiling heat transfer. I: review of parametric effects of boiling, 2004.

[18]. Klaus S, Overview and discussion on pool boiling heat transfer data and correlations of ammonia, international journal of refrigeration 33 (2010) 1292-1306, 2010.

[19]. Evraam, G, et al., Local heat transfer coefficient for pool boiling of R-134a and R-123 on smooth and enhanced tubes, International Journal of Heat and Mass Transfer, Volume 55, Issues 11–12, May 2012, Pages 3021–3028, 2012.

[20]. Arthur, E, High-flux processes through enhanced heat transfer, 5th International Conference on Boiling Heat Transfer, Montego Bay, Jamaica, May 4-8, 2003.

[21]. Jeongbae, K, et al, Experimental study of pool temperature effects on nucleate pool boiling, International Journal of Multiphase Flow 32, 208–231, 2006.

[22]. Sateesh, S, et al., Analysis of pool boiling heat transfer: effect of bubbles sliding on the heating surface, International Journal of Heat and Mass Transfer 48, 2005.

[23]. Das, P, et al., Performance of different structured surfaces in nucleate pool boiling, Applied Thermal Engineering, Volume 29, Issues 17-18, December 2009.

[24]. Darabi, J, et al, Effect of Heating Boundary Conditions on Pool Boiling Experiments, HVAC&R RESEARCH VOL. 5, NO. 4, 1999.

[25]. Rohsenow, W, A Method for Correlating Heat-Transfer Data for Surface Boiling of Liquids, *Transactions of ASME*, Vol. 74, pp. 969-976, 1952.

[26]. Kutateladze, S, On the Transition to Film Boiling under Natural Convection, Kotloturbostroenie, No. 3, pp. 10–12, 1948.

[27]. Zuber, N, On the Stability of Boiling Heat Transfer, Trans. Of the ASME, v. 80, pp. 711-720, 1958.

[28]. Lienhard, H, et al., Extended hydrodynamic theory of the peak and minimum pool boiling heat fluxes ', NASA-CR-2270, 194 pages, July 1994.

[29]. Berenson, P, Film-boiling heat transfer from a horizontal surface, J. Heat Transfer, 83, 35 1 - 358, 1961.

[30]. Bromley, L, Heat transfer in stable film boiling'. Chern. Engng. Prog.; 46, 221 -227, 1950.

[31]. Labuntsov, D, Heat transfer problems with nucleate boiling of liquids, Thermal Engrg., Vol.19, pp. 21-28, 1972.

[32]. Cornwell K., et al., The Influence of Diameter on Nucleate Boiling Outside Tubes, Proceedings of The Seventh International Heat Transfer Conference, Munchen, Germany, Vol. 4, pp. 47-53, 1982.

[33]. Sarma, P, et al., A correlation to predict heat transfer coefficient in nucleate boiling on cylindrical heating elements, International Journal of Thermal Sciences 347–354, 2008.

[34]. Moon-Hyun Chun, et al., Effects of Heat Exchanger Tube Parameters on Nucleate Pool Boiling Heat Transfer, Journal of Heat Transfer MAY 1998, Vol. 120 / 468-476, 1998.

[35] Gong, S., et al., Orientation effect on heat transfer coefficient of a downward surface for flow boiling in a rectangular channel under low flow rate. International Journal of Heat and Mass Transfer, 153: p. 119594, 2020.

[36] Liu, Z. et al., A general correlation for saturated and subcooled flow boiling in tubes and annuli, based on a nucleate pool boiling equation. International journal of heat and mass transfer,. 34(11): p. 2759-2766, 1991.

[37]. Kouidri, A., et al., Experimental investigation of flow boiling in narrow channel. International Journal of Thermal Sciences, 98: p. 90-98, 2015.

[38]. Piasecka, M., Correlations for flow boiling heat transfer in minichannels with various orientations. International Journal of Heat and Mass Transfer, 81: p. 114-121, 2015.

[39]. Chen, J.C., Correlation for boiling heat transfer to saturated fluids in convective flow. Industrial & engineering chemistry process design and development, 5(3): p. 322-329, 1966.

[40]. Forster, H. et al., Dynamics of vapor bubbles and boiling heat transfer. AIChE Journal, 1(4): p. 531-535, 1955.

[41]. Shah, M.M., Chart correlation for saturated boiling heat transfer: equations and further study. ASHRAE transactions, 1982.

[42]. Gungor, K. et al., Simplified general correlation for saturated flow boiling and comparisons of correlations with data. Chemical engineering research & design, 65(2): p. 148-156, 1987.

[43]. Kandlikar, S.G., A general correlation for saturated two-phase flow boiling heat transfer inside horizontal and vertical tubes. 1990.

[44] Kim, B. et al., An experimental study of flow boiling in a rectangular channel with offset strip fins. International journal of heat and fluid flow, 27(3): p. 514-521, 2006.

[45] Özdemir, M.R., et al., Flow Boiling of Water in a Rectangular Metallic Microchannel. Heat Transfer Engineering, 2020.

[46]. Hsu, Y, et al., Approximate theory for film boiling on vertical surfaces. Chem. Eng. Progr., 1960.

[47]. Dougall, R.S., Film boiling on the inside of vertical tubes with upward flow of the fluid at low qualities, Massachusetts Institute of Technology, 1963.

[48]. Analytis, G, et al., Analytical modeling of inverted annular film boiling. Nuclear Engineering and Design, 1987.

[49]. Takenaka, N., et al., Flow pattern transition and heat transfer of inverted annular flow. International Journal of Multiphase Flow, 1989.

[50]. Cachard, F., Development, Implementation, and Assessment of Specific Closure Laws for Inverted-Annular Film-Boiling. 1996.

[51]. Elias, E, et al., Inverted-annular film boiling heat transfer from vertical surfaces. Nuclear Engineering and Design, **64**(2): p. 249-257, 1981.

[52]. Hammouda, N., et al., Two-fluid modelling of inverted annular film boiling. International journal of heat and mass transfer, **40**(11): p. 2655-2670, 1997.

[53]. Sindhuja, R., et al., Post-CHF heat transfer during two-phase upflow boiling of R-407C in a vertical pipe. Applied Thermal Engineering, **30**(2-3): p. 167-173, 2010.

[54]. El Nakla, M., et al., Modeling subcooled flow film boiling in a vertical tube. Journal of Thermal Science and Engineering Applications, **2**(2): p. 021002, 2010.

[55]. CHEN, C. J. Correlation for boiling heat transfer to saturated fluids in convective flow. Industrial & Engineering Chemistry Process Design And Development, v. 5, p. 322-329, 1966.

[56]. Shah, M.M, Chart correlation for saturated boiling heat transfer: Equations and further study, ASHRAE Trans. 88. 185–195, 1982.

[57]. Gungor, K, et al., A general correlation for flow boiling in tubes and annuli, Int. J. Heat Mass Transf. 29 . 351–358, 1985.

[58].Kenning, M, et al., Saturated flow boiling of water in vertical tubes, Int. J. Heat Mass Transf. 32 .445–458, 1989.

[59]. Kandlikar, S, et al., General Correlation for Saturated Two-Phase Flow Boiling Heat Transfer Inside Horizontal and Vertical Tubes. Journal of Heat Transfer, v. 112, p. 219-228, 1990.

[60]. Liu, Z, et al., A general correlation for saturated and subcooled flow boiling in tubes and annuli, based on a nucleate pool boiling equation, Int. J. Heat Mass Transf. 34 .2759–2766. 1991.

[61]. Lazareck, G, et al., Evaporative heat transfer, pressure drop and critical heat flux in a small vertical tube with R-113, Int. J. Heat Mass Transf. 25 .945–960, 1982.

[62]. Kattan, N, et al., Flow Boiling in Horizontal Tubes: Part 1—Development of a Diabatic Two-Phase Flow Pattern Map, J. Heat Transfer 120 .140–147, 1998.

[63]. Wojtan, T, et al., Investigation of flow boiling in horizontal tubes: Part I—A new diabatic two-phase flow pattern map, Int. J. Heat Mass Transf. 48 .2955–2969, 2005.

[64]. CHENG, L, et al., New flow boiling heat transfer model and flow pattern map for carbon dioxide evaporating inside horizontal tubes. International Journal of Heat and Mass Transfer, v. 49, p. 4082- 4094, 2006.

[65]. Zhang, W, et al., Correlation for flow boiling heat transfer in mini-channels, Int. J. Heat Mass Transf. 47 .5749–5763, 2004.

[66]. Kim, S, et al., Universal approach to predicting saturated flow boiling heat transfer in mini/micro-channels – Part II. Two-phase heat transfer coefficient, Int. J. Heat Mass Transf. 64 .1239–1256, 2013.

[67]. Dadhich, M., et al., Flow boiling heat transfer analysis of Al_2O_3 and TiO_2 nanofluids in horizontal tube using artificial neural network (ANN). Journal of Thermal Analysis and Calorimetry, 139(5): p. 3197-3217, 2020.

[68] Bouali, A., et al., Using artificial neural network for predicting heat transfer coefficient during flow boiling in an inclined channel. Thermal Science, p. 238-238, 2020.

[69] Mohamedi, B., et al., Simulation of nucleate boiling under ANSYS-FLUENT code by using RPI model coupling with artificial neural networks. Nuclear Science and Techniques, 26(4): p. 40601-040601, 2015.

[10] Qiu, Y., et al., An artificial neural network model to predict mini/micro-channels saturated flow boiling heat transfer coefficient based on universal consolidated data. International Journal of Heat and Mass Transfer, 149: p. 119211, 2020.

[71]. PANDA, et al., Machine learning assisted modeling of thermohydraulic correlations for heat exchangers with twisted tape inserts. arXiv preprint arXiv:2202.00927, 2022.

[72]. Ghalem, N., et al., Prediction of thermal conductivity of liquid and vapor refrigerants for pure and their binary, ternary mixtures using artificial neural network. Thermophysics and Aeromechanics, 26(4): p. 561-579, 2019.

[73]. Sun, Z, et al., Neural networks approach for prediction of gas–liquid two-phase flow pattern based on frequency domain analysis of vortex flowmeter signals. Measurement Science and Technology, 19(1): p. 015401, 2007.

[74]. Skrypnik, et al. Artificial neural networks application on friction factor and heat transfer coefficients prediction in tubes with inner helical-finning. Applied Thermal Engineering, p. 118049, 2022.

[75]. Thibault, J. et al., A neural network methodology for heat transfer data analysis. International Journal of Heat and Mass Transfer, 34(8): p. 2063-2070, 1991.

[76]. Diaz, G., et al. Analysis of data from single-row heat exchanger experiments using an artificial neural network. in The 1996 ASME International Mechanical Engineering Congress and Exposition, Atlanta, GA, USA, 11/17-22/96. 1996.

[77]. Pacheco-Vega, A.J., Simulation of compact heat exchangers using global regression and soft computing, Citeseer, 2002.

[78]. Pacheco-Vega, A., et al., Neural network analysis of fin-tube refrigerating heat exchanger with limited experimental data. International Journal of Heat and Mass Transfer, 44(4): p. 763-770, 2001.

[79]. Pacheco-Vega, A., et al., Heat rate predictions in humid air-water heat exchangers using correlations and neural networks. J. Heat Transfer, 123(2): p. 348-354, 2000.

[80]. Benimam, H., et al., Dragonfly-Support Vector Machine for Regression Modeling of the Activity Coefficient at Infinite Dilution of Solutes in Imidazolium Ionic Liquids Using σ-Profile Descriptors. Journal of Chemical & Engineering Data, 2020.

[85]. Das, P.K., et al., Synthesis and characterization of TiO_2–water nanofluids with different surfactants. International Communications in Heat and Mass Transfer, 75: pp. 341-348, 2016.

[86]. Sadripour, S., Investigation of Flow Characteristics And Heat Transfer Enhancement in a Nanofluid Flow in a Corrugated Duct. Journal of Applied Mechanics and Technical Physics, 59: pp.1049-1057, 2018.

[87]. Song, G., et al., Nucleate pool boiling heat transfer of SES36 fluid on nanoporous surfaces obtained by electrophoretic deposition of Al2O3. Applied Thermal Engineering, 141: pp. 143-152, 2018.

[88]. Kandasamy, R., et al., Magnetohydrodynamic and heat transfer effects on the stagnation-point flow of an electrically conducting nanofluid past a porous vertical shrinking/stretching sheet in the presence of variable stream conditions. Journal of Applied Mechanics and Technical Physics, 58: pp. 71-79, 2017.

[89].Vafaei, S. et al., Role of nanoparticles on nanofluid boiling phenomenon: Nanoparticle deposition. Chemical Engineering Research and Design, 92: pp. 842-856, 2014.

[90]. Shoghl, S.N., Experimental investigation on pool boiling heat transfer of ZnO, and CuO water-based nanofluids and effect of surfactant on heat transfer coefficient. International communications in heat and mass transfer, 45: pp. 122-129, 2013.

[91]. Mukherjee, S., et al., Experimental investigation on thermo-physical properties and subcooled flow boiling performance of Al_2O_3/water nanofluids in a horizontal tube. International Journal of Thermal Sciences, 159: p. 106581, 2021.

[92]. Vanaki, S.M., et al., Effect of nanoparticle shapes on the heat transfer enhancement in a wavy channel with different phase shifts. Journal of Molecular Liquids, 196: pp. 32-42, 2014.

[93]. Elias, M.., et al., Effect of nanoparticle shape on the heat transfer and thermodynamic performance of a shell and tube heat exchanger. International Communications in Heat and Mass Transfer, 44: pp. 93-99, 2013.

[94]. Khooshechin, M., et al., The influence of surfactant and ultrasonic processing on improvement of stability and heat transfer coefficient of CuO nanoparticles in the pool boiling. International Journal of Heat and Mass Transfer, 154: p. 119783, 2020.

[95]. Tian, Z., Etedali, S., Afrand, M., Abdollahi, A. and Goodarzi, M., Experimental study of the effect of various surfactants on surface sediment and pool boiling heat transfer coefficient of silica/DI water nano-fluid. Powder Technology, 356: pp. 391-402, 2019.

[96]. Almanassra, I.W., et al., An experimental study on stability and thermal conductivity of water/CNTs nanofluids using different surfactants: A comparison study. Journal of Molecular Liquids, 304: p. 111025, 2020.

[97]. Chen, H., et al., Heat transfer and flow behaviour of aqueous suspensions of TiO2 nanoparticles (nanofluids) flowing upward through a vertical pipe. International journal of heat and mass transfer, 50: pp. 2272-2281, 2007.

[98]. Park, K.J., et al., Nucleate boiling heat transfer in aqueous solutions with carbon nanotubes up to critical heat fluxes. International Journal of Multiphase Flow, 35: pp. 525-532, 2009.

[99].Okawa, T., et al., Boiling time effect on CHF enhancement in pool boiling of nanofluids. International Journal of Heat and Mass Transfer, 55: pp. 2719-2725, 2012.

[100]. Ahn, H.S, et al., The boiling phenomenon of alumina nanofluid near critical heat flux. International Journal of Heat and Mass Transfer, 62: pp. 718-728, 2013.

[101]. Diao, Y., et al., Experimental investigation of the Cu/R141b nanofluids on the evaporation/boiling heat transfer characteristics for surface with capillary micro-channels. Heat and Mass Transfer, 50: pp. 1261-1274, 2014.

[102]. Duursma, G., et al., Flow and heat transfer of single-and two-phase boiling of nanofluids in microchannels. Heat Transfer Engineering, 36: pp. 1252-1265, 2015.

[103]. Sarafraz, M.M, et al., Comparatively experimental study on the boiling thermal performance of metal oxide and multi-walled carbon nanotube nanofluids. Powder Technology, 287: pp. 412-430, 2016.

[104]. Nikkhah, V., et al., Application of spherical copper oxide (II) water nano-fluid as a potential coolant in a boiling annular heat exchanger. Chemical and biochemical engineering quarterly, 29: pp. 405-415, 2015.

[105]. Sun, B. et al., Flow boiling heat transfer characteristics of nano-refrigerants in a horizontal tube. international journal of refrigeration, 38: p. 206-214, 2014.

[106]. Baqeri, S., et al., Experimental investigation of the forced convective boiling heat transfer of R-600a/oil/nanoparticle. International Communications in Heat and Mass Transfer, 55: p. 71-76, 2014.

[107]. Diao, Y., et al., Experimental investigation on the pool boiling characteristics and critical heat flux of Cu-R141b nanorefrigerant under atmospheric pressure. International Journal of Heat and Mass Transfer, 89: p. 110-115, 2015.

[108]. Lin, L., et al., Experimental research on particle aggregation behavior in nanorefrigerant–oil mixture. Applied Thermal Engineering, 98: p. 944-953, 2016.

[109].Yang, D., et al., Experimental study on the heat transfer and flow characteristics of nanorefrigerants inside a corrugated tube. International Journal of Refrigeration, 56: p. 213-223, 2015.

[110].Rajabnia, H., et al., Experimental investigation of subcooled flow boiling of water/TiO2 nanofluid in a horizontal tube. Thermal Science, 20(1): p. 99-108, 2016.

[111].Henderson, K., et al., Flow-boiling heat transfer of R-134a-based nanofluids in a horizontal tube. International Journal of Heat and Mass Transfer, 53(5-6): p. 944-951, 2010.

[112].Baniamerian, Z., Analytical modeling of boiling nanofluids. Journal of Thermophysics and Heat Transfer, 31(1): p. 136-144, 2017.

[113].Dadhich, M., et al., Flow boiling heat transfer analysis of Al_2O_3 and TiO_2 nanofluids in horizontal tube using artificial neural network (ANN). Journal of Thermal Analysis and Calorimetry, 139(5): p. 3197-3217, 2020.

[114].Mukherjee, S., Jana, S., Mishra, P.C., Chaudhuri, P. and Chakrabarty, S., Experimental investigation on thermo-physical properties and subcooled flow boiling performance of Al_2O_3/water nanofluids in a horizontal tube. International Journal of Thermal Sciences, 159: p. 106581, 2021.

[115].Wang, Y., et al., A mechanism of heat transfer enhancement or deterioration of nanofluid flow boiling heat transfer. International Journal of Heat and Mass Transfer, 158: p. 119985, 2020.

[116]. Moreira, T.A., et al., Flow boiling heat transfer coefficient of DI water and nanofluids inside microscale channels under conditions near the critical heat flux (CHF). Journal of the Brazilian Society of Mechanical Sciences and Engineering, 43(6): p. 1-16, 2021.

[117].Nakhjavani, S. et al., flow boiling heat transfer characteristics of titanium oxide/water nanofluid (tio2/di water) in an annular heat exchanger. journal of thermal engineering, 6(4): p. 592-603, 2020.

[118].Hashemi, M, et al., Study of flow boiling heat transfer characteristics of critical heat flux using carbon nanotubes and water nanofluid. Journal of Thermal Analysis and Calorimetry, 130(3): p. 2199-2209, 2017.

[119]. Ciloglu, D. et al., A comprehensive review on pool boiling of nanofluids. Applied Thermal Engineering 84 45–63, 2015.

[120]. Faukner, D, et al., Practical design of a 1000 W/cm^2 cooling system, Proc. of 19th IEEE SEMI-THERM Symposium, San Jose, CA, March 11–13, 2003

[121]. Peng, G, et al., Heat transfer characteristics of refrigerant-based nanofluid flow boiling inside a horizontal smooth tube, Int. J. Refrigeration 32 .1259–1270, 2009.

[122]. Kim, T. et al., Subcooled flow boiling heat transfer of dilute alumina, zinc oxide, and diamond nanofluids at atmospheric pressure, Nuclear Engineering and Design 240 .1186–1194, 2010.

[123]. Boudouh, H., Gualous, et al., Local convective boiling heat transfer and pressure drop of nanofluid in narrow rectangular channels, Applied Thermal Engineering 30(17– 18) ,2619–2631, 2010.

[124]. Henderson, K. et al., Flow-boiling heat transfer of R-134a-based nanofluids in a horizontal tube, Int. J. Heat Mass Transfer 53(5–6).944–951, 2010.

[125]. Xu, J. Nanofluid stabilizes and enhances convective boiling heat transfer in a single microchannel, Int. J. Heat Mass Transfer 55(21–22) ,5673–86, 2012.

[126]. Abedini, E. et al., Experimental investigation and comparison of subcooled flow boiling of TiO_2 nanofluid in a vertical and horizontal tube, Proc IMechE Part C: J. Mechanical Engineering Science 227 (8),1742– 1753, 2013.

[127]. Peng, H. Ding, et al., Heat transfer characteristics of refrigerant-based nanofluid flow boiling inside a horizontal smooth tube, Int. J. Refrigeration 32. 1259–1270, 2009.

[128]. Rana, K, et al., Agrawal, A visualization study of flow boiling heat transfer with nanofluids, J. Visualization 16(2).133–143, 2013.

[129]. Rana, K, et al., Measurement of void fraction in flow boiling of ZnO–water nanofluids using image processing technique, Nuclear Engineering and Design 270, 2013.

[130]. Sun, D. Yang, Flow boiling heat transfer characteristics of nano-refrigerants in a horizontal tube, Int. J. Refrigeration 38 .206–214, 2014.

[131]. Sarafraz, M, et al., Scale formation and subcooled flow boiling heat transfer of CuO–water nanofluid inside the vertical annulus, Experimental Thermal and Fluid Science 52 205–214, 2014.

[132]. Longo, G.A., et al., Application of an Artificial Neural Network (ANN) for predicting low-GWP refrigerant boiling heat transfer inside Brazed Plate Heat Exchangers (BPHE). International Journal of Heat and Mass Transfer, 160: p. 120204, 2020.

[133]. Bahman, A. et al., Prediction of the minimum film boiling temperature using artificial neural network. International Journal of Heat and Mass Transfer, 155: p. 119834, 2020.

[134]. Zarei, M., et al., Prediction of pool boiling heat transfer coefficient for various nano-refrigerants utilizing artificial neural networks. Journal of Thermal Analysis and Calorimetry, p. 1-12, 2019.

[135]. Maleki, A., et al., Thermal conductivity modeling of nanofluids with ZnO particles by using approaches based on artificial neural network and MARS. Journal of Thermal Analysis and Calorimetry, 2020.

[136].Kahani, M., et al., Application of M5 tree regression, MARS, and artificial neural network methods to predict the Nusselt number and output temperature of CuO based nanofluid flows in a car radiator. International Communications in Heat and Mass Transfer, 2020.

[137]. Belmadani, S., et al., Artificial Neural Network Models for Prediction of Density and Kinematic Viscosity of Different Systems of Biofuels and Their Blends with Diesel Fuel. Comparative Analysis. Kemija u Industriji, 2020.

[138].Ammi, Y., et al., A Comparison of" Neural Networks and Multiple Linear Regressions" Models to Describe the Rejection of Micropollutants by Membranes. Kemija u Industriji, 2020.

[139].Barki, H., et al., Modelling of Adsorption of Methane, Nitrogen, Carbon Dioxide, Their Binary Mixtures, and Their Ternary Mixture on Activated Carbons Using Artificial Neural Network. Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske, 2019.

[140]. Ahmadi, M.H., et al., A proposed model to predict thermal conductivity ratio of Al 2 O 3/EG nanofluid by applying least squares support vector machine (LSSVM) and genetic algorithm as a connectionist approach. Journal of Thermal Analysis and Calorimetry, 2019.

[141]. Dong, F., et al., Simulation of subcooled flow boiling with an SVR based interphase mass transfer model. Applied Thermal Engineering, 2017.

[142]. Akay, O.E. et al., Modeling the total heat transfer coefficient of a nuclear research reactor cooling system by different methods. Case Studies in Thermal Engineering, 2021.

[143]. Ahmadi, M.H., et al., Thermal conductivity ratio prediction of Al2O3/water nanofluid by applying connectionist methods. Colloids and Surfaces A: Physicochemical and Engineering Aspects, 2018.

[144]. Mesellem, Y., et al., Computational intelligence techniques for modeling of dynamic adsorption of organic pollutants on activated carbon. Neural Computing and Applications, 2021.
[145]. Nguyen, A, et al., a review on simulation-based optimization methods applied to building performance analysis. *Applied Energy, 113*, 1043-1058, 2014.

[146]. Zerdoumi, Z, Application des réseaux de neurones artificiels à lapoursuite des non linéarités fluctuantes des systèmes satellitaires, mémoire de magister Université Mohamed Boudiaf, M'sila, Algérie 2006.

[147]. Souabi, M et al., conception d'un système hybride neuro markovien RN-MLP & MRF pour la classification des images satellitaires, PFE, USTO, Algérie 2006.

[148]. Muxika, A,. Application des Réseaux de Neurones a l'Identification d'un Axe de Machine-Outil", Thèse de doctorat, INPG, 2002.

[149]. Touzet, C,. Les Réseaux de Neurones Artificiels - Introduction au Connexionnisme", cours, exercices et travaux pratiques. Juillet 1992.

[150]. Ouali, A,. Evaluation de la Stabilité Transitoire des Réseaux Électriques par les Réseaux de Neurones Artificiels et les Plans d'Expériences", Mémoire de Magister, Université de Constantine, 2005.

[151]. Parizeau, R,. Réseaux de neurones. Université Laval, Automne2004.

[152]. Boser, B, et al., A training algorithm for optimal margin classi- fiers. In Proceedings of the fifth annual workshop on Computational learning theory, pages 144–152. ACM, 1992.

[153]. Guyon, B, et al., Automatic capacity tuning of very large vc-dimension classifiers. In Advances in neural information processing systems. Citeseer, 1993.

[154]. Vapnik, N, *Statistical Learning Theory*. Edition Wiley, 1998.

[155]. Vapnik, N, *The nature of statistical learning theory*. Springer, 2000

[156].Haykin, S., Neural Networks: A Comprehensive Foundation, Prentice Hall PTR. Upper Saddle River, NJ, USA, 1998.

[157].Thanikodi, S., et al., Tlonn for the effective prediction of heat transfer rates in tube heat exchangers. Thermal Science, p. 438-438, 2019.

[158].Özdemir, M.R., et al., Flow Boiling of Water in a Rectangular Metallic Microchannel. Heat Transfer Engineering, 2020.

[159].Maouz, H., et al., Modeling the molecular weight and number average molecular masses during the photo-thermal oxidation of polypropylene using neural networks. Moroccan Journal of Chemistry, 2019.

[160].Benimam, H., et al., Dragonfly-Support Vector Machine for Regression Modeling of the Activity Coefficient at Infinite Dilution of Solutes in Imidazolium Ionic Liquids Using σ-Profile Descriptors. Journal of Chemical & Engineering Data, 2020.

[161].Ross, T., Indices for performance evaluation of predictive models in food microbiology. Journal of Applied Bacteriology, 1996. 81(5): p. 501-508.

[162].Golbraikh, A. and A. Tropsha, Beware of q^2. Journal of molecular graphics and modelling, 2002.

[163].Garson, D.G., Interpreting neural network connection weights. 1991.

[164].Hamzaoui, Y.E., et al., Optimal performance of COD removal during aqueous treatment of alazine and gesaprim commercial herbicides by direct and inverse neural network. Desalination, 2011.

[165].Demuth, H. and M. Beale, Matlab neural network toolbox user's guide version 6. The MathWorks Inc. 2009.

[166].International atomique energy agency IAEA, ''thermohydraulic relationships for advanced water cooled reactors,IAEA-TECDOC-1203,april 2001.

[167].Fahlman, S.E. and C. Lebiere. The cascade-correlation learning architecture. in Advances in neural information processing systems. 1990.

[168].Kisi, O. and Z.M. Yaseen, The potential of hybrid evolutionary fuzzy intelligence model for suspended sediment concentration prediction. Catena, 2019.

[169] .Haykin, S., Neural networks: a comprehensive foundation. 2007.

[170].Sanikhani, H., et al., Non-tuned data intelligent model for soil temperature estimation: A new approach. Geoderma, 2018.

[171].Setoodeh, H., et al., Subcooled flow boiling of alumina/water nanofluid in a channel with a hot spot: An experimental study. Applied Thermal Engineering, 2015.

[172].Sarafraz, M.M. and F. Hormozi, Scale formation and subcooled flow boiling heat transfer of CuO–water nanofluid inside the vertical annulus. Experimental Thermal and Fluid Science, 2014.
[173].Goh, A.T., Back-propagation neural networks for modeling complex systems. Artificial intelligence in engineering, 1995.

[174]. Kavitha, R., et al., A comparison between MLP and SVR models in prediction of thermal properties of nano fluids. J. Appl. Fluid Mech, 2018.

[175].Vapnik, V., The nature of statistical learning theory. Springer science & business media, 2013.

[176]. Keskes, S., et al., Artificial intelligence and mathematical modelling of the drying kinetics of pharmaceutical powders. Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske, 2020.