République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITE DE MEDEA

Département de Génie Mécanique

Laboratoire de Biomatériaux et Phénomènes de Transport (LBMPT)

Thèse de Doctorat

Présentée par :

Mr.BENYKHLEF Ahmed

Ingénieur d'Etat en Génie Mécanique: Université de Médéa, Algérie

Master en Energie et Froid Industriel : Université de Médéa, Algérie

En vue de l'obtention du titre de Doctorat : Génie Mécanique

Option : Energétique Nucléaire

Thème

Contribution à la modélisation de l'encrassement des échangeurs de chaleur

Dirigée par : Professeur Salah. HANINI (Université de Médéa)

Docteur Brahim. MOHAMMEDI (Maître de Recherche A, CRNB)

2020-2021

Soutenue le 28/06/2021 devant le jury composé de :

Mr. Mohamed Nadjib BOUAZIZ	Professeur, Université de Médéa	Président de jury
Mr. Abdelkader HAMID	Professeur, USDB1, Blida	Examinateur
Mr. Mohamed ROUDANE	MCA, USDB1, Blida	Invité
Mr. Salah HANINI	Professeur, Université de Médéa	Directeur de Thèse
Mr. Brahim MOHAMMEDI	Dr, CRNB, Centre Nucléaire de Birine	Co-Directeur de Thèse

Je dédie cette thèse à :

Mes parents

Mon petit prince Othmane

Ma petite princesse Loudjaine

Ma femme (Oum Othmane et Loudjaine)

Ma famille

Tous mes amis et collègues

Tous ceux qui m'ont soutenu et m'ont encouragé

*Le plus grand merci revient à **ALLAH** qui nous a guidés dans le bon sens durant notre vie qui nous aide à réaliser ce travail.*

*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 remercie Monsieur **BOUAZIZ Mohamed Nadjib**, Professeur à l'Université Yahia Farés de Médéa, pour m'avoir fait l'honneur d'accepter la présidence du jury de soutenance.*

*Je profite de l'occasion de la présentation de ce travail pour exprimer mes vifs remerciements à Monsieur **Abdelkader HAMID**, Professeur à l'Université Saad DAHLEB1 de BLIDA, d'avoir accepté de faire partie de ce jury.*

*Je tiens également à présenter ma profonde gratitude à Monsieur **Mohamed ROUDANE**, Maître de Conférences A à l'Université Saad DAHLEB1 de BLIDA, d'avoir accepté de juger ce travail.*

*J'adresse des pensées reconnaissantes à mon entourage pour ses encouragements, en particulier à Monsieur **Maamar LAIDI** et **Ahmed REZRAZI** pour l'aide et les soutiens permanentes dont il m'a fait bénéficier durant la période de travail.*

En fin nous remercions tous ceux qui ont participé de près ou de loin à l'achèvement de ce travail.

Résumé : Contribution à la modélisation de l'encrassement des échangeurs de chaleur

La conception des réacteurs nucléaires, repose sur un assemblage complexe de systèmes thermodynamiques interconnectés de façon à générer une grande quantité de chaleur, produite par le phénomène de fission de noyaux lourds du combustible nucléaire dans le cœur du réacteur. Cette chaleur alimentera un autre usage à savoir la production de vapeur pour un travail mécanique, production de l'électricité, production de radio-isotope ou production d'eau douce par dessalement ou son évacuation vers l'environnement à travers les tours de refroidissement dans le cas des réacteurs de recherches. Il est indispensable, lors de la conception des systèmes thermo hydraulique des installations nucléaires tels que les échangeurs de chaleur et les assemblages combustibles de prendre en compte tous les phénomènes possibles pouvant affecter le transfert de chaleur, en considérant tous les régimes de fonctionnement.

L'objectif principal de cette étude est d'apporter notre contribution à la modélisation de l'encrassement des échangeurs de chaleur.

Une contribution préliminaire consiste à la modélisation qui traite d'une façon détaillée la méthodologie d'optimisation du modèle neuronal et un modèle de machine à vecteur de support pour la prédiction de la résistance à l'encrassement dans un échangeur à contre-courant. Les deux modèles basés sur le phénomène d'encrassement ont été comparés et sélectionné le meilleure modèle entre eux. Les résultats obtenus ont montré que le modèle neuronale (RNA) donne un bon accord entre les valeurs estimées et expérimentales, avec un coefficient de régression R dépassant 99.999 %.

Dans la deuxième contribution, nous avons abordé la modélisation par la technique neuronale basée sur un réseau de neurones artificiels direct et inverse de l'optimisation du modèle RNA pour prédire la résistance à l'encrassement dans l'échangeur-condenseur qui a été développée et appliquée en utilisant une base de données expérimentale d'un échangeur de chaleur-condenseur d'une centrale nucléaire. Cette méthodologie est basée sur la sélection des paramètres adimensionnelle de l'entrée et de sortie, la sélection de la structure du RNA, l'algorithme d'apprentissage, la technique de normalisation et l'architecture du réseau. Cela nous a permis d'atteindre un modèle neuronale direct et inverse optimal. Après une comparaison de ce modèle avec des résultats à d'autres recherches dans le même contexte, nous pouvons dire que notre modèle donne de meilleures performances en terme d'erreurs et de coefficient de corrélation avec un MAPE de 0.1295 %, un RMSE de3.6588×10^{-07}et une précision des sorties allant de 99.998 %.

L'objectif de la troisième contribution, est le développement d'un modèle de RNA-MLP valable pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides (MgO-eau et CuO-eau) à partir de données expérimentales de l'échangeur de chaleur en fonction du temps, de la concentration volumétrique, du flux thermique, du débit massique et de la Température d'entrée du fluide. La détermination de l'effet de chacun des paramètres d'entrée sur la résistance à l'encrassement, en particulier l'effet des différentes concentrations de particules, d'une part. Et d'autre part, c'est la plus haute précision du modèle RNA-MLP développé par rapport aux corrélations proposées pour la prédiction de la résistance à l'encrassement. Les résultats obtenus sont très satisfaisants et très précis avec un coefficient de détermination de 99,77% et une MSE de 6.2119×10^{-04}.

Mots clés : Modélisation, Prédiction, Echangeur de chaleur, Résistance d'encrassement, Réseau de neurones artificiels direct, Réseau de neurones artificiels inverse, Interface graphique.

Abstract: Contribution to the modeling of fouling of heat exchangers

The design of nuclear reactors is based on an assembly complex of thermodynamic systems interconnected so as to generate a large quantity of heat, produced by the phenomenon of fission of heavy nuclei of nuclear fuel in the reactor core. This heat will feed into another use, namely the production of steam for mechanical work, production of electricity, production of radioisotope or production of fresh water by desalination or its evacuation towards to the environment through the cooling towers in the case of research reactors. When designing thermal-hydraulic systems for nuclear installations, such as heat exchangers and fuel assemblies, it is essential to take into account all possible phenomena that may affect heat transfer, considering all operating diets.

The main objective of this study is to make our contribution to the modeling of the fouling of heat exchangers.

A preliminary contribution consists of modeling which discusses in detail the optimization methodology of the neural model and a support vector machine model for the prediction of resistance to fouling in a counter-current heat exchanger. The two models based on the fouling phenomenon were compared and selected the best model between them. The results obtained showed that the neuronal model (ANN) gives a good agreement between the estimated and experimental values, with a regression coefficient R exceeding 99.999%.

In the second contribution, we approached the modeling by the neural technique based on a direct and inverse artificial neural network of the optimization of the ANN model to predict the resistance to fouling in the heat exchanger-condenser was developed and applied using an experimental database of a heat exchanger-condenser of a nuclear power plant. This methodology is based on the selection of dimensionless input and output parameters, the selection of the ANN structure, the learning algorithm, the normalization technique and the network architecture. This allowed us to achieve an optimal direct and inverse neural model. After a comparison of this model with results from other research in the same context, we can say that our model gives better performance in terms of errors and correlation coefficient with a MAPE of 0.1295%, an RMSE of 3.6588×10^{-07} and output accuracy ranging from 99.998%.

The objective of the third contribution is the development of a valid ANN-MLP model for the prediction of the resistance to fouling in the heat exchanger with nanofluids (MgO-water and CuO-water) from data experiments of the heat exchanger as a function of time, volumetric concentration, heat flow, mass flow and fluid inlet temperature. The determination of the effect of each of the input parameters on the resistance to fouling, in particular the effect of different concentrations of particles, on the one hand. And on the other hand, it is the highest precision of the ANN-MLP model developed with respect to the correlations proposed for the prediction of the resistance to fouling. The results obtained are very satisfactory and very precise with a coefficient of determination of 99.77% and an MSE of 6.2119×10^{-04}.

Keywords: Modeling, Prediction, Heat exchanger, Fouling resistance, Direct artificial neural network, Inverse artificial neural network, Graphical interface.

الملخص: المساهمة فينمذجة تراكم عناصر صلبة في المبادلات الحرارية

يعتمد تصميم المفاعلات النووية على مجموعة معقدة من الأنظمة الديناميكية الحرارية المترابطة لتوليد كمية كبيرة من الحرارة الناتجة عن ظاهرة انشطار النواة الثقيلة للوقود النووي في قلب المفاعل. ستغذي هذه الحرارة استخدامًا آخر، وهو إنتاج البخار للأعمال الميكانيكية، أو إنتاج الكهرباء، أو إنتاج النظائر المشعة أو إنتاج المياه العذبة عن طريق التحلية أو تفريغها إلى البيئة من خلال أبراج التبريد في حالة مفاعلات الأبحاث. من الضروري، عند تصميم الأنظمة الحرارية الهيدروليكية للمنشآت النووية مثل ا لمبادلات الحرارية وتجميع الوقود، مراعاة جميع الظواهر المحتملة التي قد تؤثر على انتقال الحرارة، مع مراعاة جميع أنظمة التشغيل.

الهدف الرئيسي من هذه الدراسة هو المساهمة في نمذجة تراكم عناصر صلبة في المبادلات الحرارية.

تعتمد المساهمة الأ ولية من النمذجة التي تتعامل بطريقة مفصلة المنهجية لتحسين النموذج العصبي ونموذج آلة ناقلات الدعم للتنبؤ بمقاومة تراكم عناصر صلبة في المبادل الحراري معكوس التنقل . حيث تمت مقارنة كلا النموذجين بناء على ظاهرة تراكم العناصر الصلبة واختيار أفضل نموذج بينهما. أظهرت النتائج التي تم الحصول عليها أن النموذج العصبي (الشبكة العصبية الاصطناعية) يعطي اتفاق جيد بين القيم المقدرة والتجريبية، مع معامل الانحدار التجريبي 99.999%.

في المساهمة الثانية، ناقشنا النمذجة من قبل تقنية الخلايا العصبية القائمة على شبكة الخلايا العصبية الاصطناعية المباشرة والعكسية لتحسين شبكة الخلايا العصبية الاصطناعية للتنبؤ في مبادل المكثف ويتم تطبيقها باستخدام قاعدة معطيات تجريبية لمبادل حراري من محطة للطاقة النووية. تعتمد هذه المنهجية على تحديد عناصر الإدخال والإخراج بدون وحدة، واختيار هيكل شبكة الخلايا العصبية الاصطناعية، خوارزمية التعلم، تقنية التطبيع والهندسة المعمارية للشبكة. هذا سمح لنا بالوصول الى نموذج عصبي مباشر وعكسي امثل. بعد مقارنة هذا النموذج بنتائج عمليات علمية أخرى في نفس السياق، يمكننا أن نقول أن نموذجنا أعطي أداء أفضل للأخطاء ومعامل الارتباط MAPE بلغ 0.1295 %، و RMSE 3.6588×10^{-07} ودقة مخرجات تتراوح بين 99.998%.

أما المساهمة الثالثة، هي تطوير نموذج من RNA-MLP صالحا للتنبؤ في مقاومة تراكم عناصر صلبة في مبادل حراري يعمل بنانو السوائل (MgO-eau وCuO-eau) من مبادل حراري تجريبي للبيانات بدلالة الزمن، التركيز ألحجمي، التدفق الحراري، تدفق الشامل ودرجة حرارة مدخل السوائل. تحديد تأثير كل من معايير المدخل على مقاومة تراكم العناصر الصلبة ، ولا سيما تأثير تركيزات مختلفة من الجزيئات، من ناحية. ومن ناحية أخرى، فإن النموذج RNA-MLP المتطور أعطى أعلى دقة مقارنة بالترشيح المقترح للتنبؤ بمقاومة تراكم العناصر الصلبة . النتائج التي تم الحصول عليها مرضية ودقيقة للغاية مع معامل تحديد بلغ 99.7 % و.MSE 6.2119×10^{-04}.

الكلمات المفتاحية : النمذجة، التنبؤ، مبادل حراري، مقاومة تراكم العناصر الصلبة، شبكة الخلايا العصبية الاصطناعية المباشرة، شبكة الخلايا العصبية الاصطناعية العكسية، واجهة رسومية.

Dédicaces i
Remerciements ii
Résumé iii
Table des matières vi
Nomenclature ix
Liste des tableaux xi
Liste des figures xii
Introduction générale 2
Chapitre I : Généralités sur le phénomène d'encrassement dans les échangeurs de chaleur
I-1. Introduction 6
I-2.Notions sur les échangeurs de chaleur 6
I.2.1. Modes d'écoulement des deux fluides 7
I.2.1.1. Ecoulement co-courants 7
I.2.1.2. Ecoulement contre courants 8
I.2.1.3. Ecoulement des fluides croisés avec ou sans brassage 8
I.3. Echangeurs tubulaires 9
I.3.1.Echangeur de chaleur à double tube 9
I.3.2. Analyse thermique des tuyaux intérieurs 10
I.4. Cinétique de l'encrassement 10
I.4.1. Modèles d'évolution de l'encrassement 11
I.4.2. Facteurs d'encrassement 13
I.4.3. Corrélations empiriques sur la résistance à l'encrassement 14
I.5. Encrassement des surfaces d'échanges dans l'industrie thermiques 14
I.5.1.Conséquences des phénomènes d'encrassement 15
I.5.2. Impact du changement du facteur d'encrassement et de la température de refroidissement de l'eau de mer sur l'échangeur de chaleur 16
1.6. Encrassement des surfaces d'échanges dans l'industrie laitier : positionnement et enjeux 17
I.6.1.Importance du secteur laitier Français et enjeux de maitriser les encrassements 17
I.6.2. Aspect physique de l'encrassement 17
I.6.3. Aspect économique et environnemental de l'encrassement 18
I.7.Catégories et types d'encrassement 19
I.7.1. Encrassement particulaire 19
I.7.2.Entartrage 20
I.7.3.Corrosion 21
I.7.4. Encrassement biologique 21
I.7.5. Encrassement par réaction chimique 22
I.7.6.Encrassement par solidification 22
I.8.Nature du dépôt 22
I.8.1. Dépôt dur 22
I.8.2. Dépôt poreux 22
I.8.3. Dépôt mou 22
I.9. Processus fondamentaux de l'encrassement 23
I.9.1. L'initiation 23
I.9.2. Transport 24
I.9.3. Déposition 24
I.9.4. Réentraînement (Enlèvement) 24
I.9.5. Vieillissement 25
I.10. Conclusion 25
Chapitre II : Etat de l'art sur la modélisation de l'encrassement des échangeurs de chaleur
II.1. Introduction 28
II.2.Production scientifique mondiale sur la modélisation de l'encrassement des échangeurs de chaleur 28
II.3. Approches de modélisation 29
II.3.1. Modèle de croissance 30
II.3.2.Approche avec découplage entre le transport interne et le flux de solide à l'interface 34
II.3.2.1. Concentration constante dans le fluide 34
II.3.2.2. Résolution du transport de matière dans le fluide 36
II.3.3. Approche avec couplage du transport interne et des flux à l'interface 38
II.4. Approche d'intelligences artificielles 39
II.4.1. Modélisation d'échangeurs de chaleur à l'aide de réseaux de neurones artificiels 40

II.4.2.Méthode des machines à vecteurs de support (SVM) **42**
II.4.3.Applications de l' RNA pour l'analyse des échangeurs de chaleur **42**
II.5.Estimation des paramètres des échangeurs de chaleur **42**
II.5.1. Estimation du coefficient de transfert de chaleur (h) **42**
II.5.2.Estimation du facteur d'encrassement (R_{fo}) **44**
II.5.3. Estimation des facteurs de friction (f) **45**
II.6.Conclusion **52**
Chapitre III : Contribution à la modélisation de l'encrassement des échangeurs de chaleur
III. Introduction **54**
Contribution Préliminaire 1 : Application par réseau de neurones artificiel et par machine à vecteur de support pour prédire l'encrassement des échangeurs de chaleur
III.1. Introduction **57**
III.1.2. Méthodologie d'optimisation d'un modèle neuronal **57**
III.1.2.1. Sélection des paramètres RNA **57**
III.1.2.2. Apprentissage de l'RNA **58**
III.1.2.3. Test de réseau **60**
III.1.2.4. Validation de réseau **62**
III.1.3. Description de méthode SVM **62**
III.1.4. Matériels et méthodes **62**
III.1.4.1. Base de données **62**
III.1.5. Résultats et discussion **64**
III.1.5.1. Résistance d'encrassement **64**
III.1.5.2. Détermination de l'importance de chaque variable d'entrée (étude de sensibilité) **69**
III.1.5.3. Interface pour la résistance à l'encrassement adimensionnelle **71**
III.1.6. Conclusion **71**
Contribution 2 : Contribution à la modélisation de la résistance à l'encrassement dans l'échangeur-condenseur par réseau de neurones artificiels direct et inverse
III.2.1. Introduction **74**
III.2.2. Approche des réseaux de neurones artificiels **75**
III.2.2.1. Technique de normalisation **76**
III.2.2.2. Fonction du transfert **77**
III.2.3. Procédure de modélisation **78**
III.2.3.1 Collection de bases de données **78**
III.2.3.2. Critères statistiques **81**
III.2.3.3. Modélisation avec des réseaux de neurones **83**
III.2.4. Résultats et discussion **87**
III.2.4.1. Réseau de neurones **87**
III.2.4.2. Analyse de sensibilité **90**
III.2.4.3. Interface graphique pour la résistance à l'encrassement sans dimension **91**
III.2.4.4.Performances optimales au moyen d'RNAi **91**
III.2.5. Comparaison avec d'autres modèles **94**
III.2.6. Conclusion **95**
Contribution3 : Une Application du réseau de neurone artificiel (RNA-MLP) pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluidesMgO-eau et CuO-eau
III.3.1. Introduction **99**
III.3.2 Modèle de réseaux de neurones artificiels **101**
III.3.3. Paramètres d'entrée et erreurs du modèle **103**
III.3.4. Résultats et discussion **105**
III.3.4.1. Configuration optimale du modèle de prédiction de réseau neurone **109**
III.3.4.2. Validation du modèle RNA **111**
III.3.4.3. Détermination de l'importance de chaque variable d'entrée **111**
III.3.4.4. Programme de résistance à l'encrassement **114**
III.3.5. Conclusion **114**
Conclusion générale **117**
Références bibliographiques **120**

Symbole	Signification	Unité
	Abréviations	
A_f	Facteur de précision	-
AG	Algorithme Génétique	-
ANFIS	Systèmes d'Inférence Neuro-Flous Adaptatifs	-
B_f	Facteur de biais	-
b_i	Valeurs de biais de la couchecachée	-
b_j	Valeurs de biais de la couchede sortie	-
BR	Algorithme de Régression Bayésienne	-
CFD	Dynamique des fluides computationnelle	-
COP	Coefficient de performance	-
DBT	Température de l'ampoule sèche	°C
FL	Logique Floue	-
GMDH	Méthode de traitement des données en groupe	-
GNN	Réseaux neuronaux génétiques	-
GRNN	Réseaux neuronaux de régression généralisée	-
K, K'	Critères d'acceptabilité	-
LM	Algorithme de Levenberg-Marquardt	-
MAPE	Erreur Relative Absolue Moyenne	%
MLP	Perceptron multicouche	-
MPE	Erreur Relative Moyenne	%
MSE	Erreur Quadratique Moyenne	%
PNN	Réseau neuronal probabiliste	-
PSO	Optimisation par Essaim de Particules	-
PVC	Chlorure de polyvinyle	-
P^*c	Pression du condenseur sans dimension	-
PW^*c	Puissance de sortie sans dimension	-
QP	Programmation quadratique	-
RAE_{max}	Erreur Absolue Relative maximale	-
RAE_{min}	Erreur Absolue Relative maximale	-
RE	Résistance à l'encrassement	m^2 °K/KW
RE*	Résistance à l'encrassement adimensionnel	-
RBFN	Réseau de fonctions de base radiale	-
RH	Humidité relative	%
RMSE	Racine sur l'Erreur Quadratique Moyenne	-
RNA	Réseau de Neurones Artificiels	-
RNAi	Réseau de Neurones Artificiels inverse	-
SAH	Aérotherme solaire	-
SLT	Théorie de l'apprentissage statistique	-
SRM	Minimisation du risque structurel	-
STDEV	Ecart-type	%

SVM	Machines à vecteur de support	-
SWH	Chauffe-eau solaire	-
TEMA	Normes des fabricants d'échangeurs tubulaires	-
T^*c	Température du condenseur sans dimension	-
T^*eau de mer	Différentes valeurs de température de l'eau de mer sans dimension	-
U^*ic	Coefficient de transfert de chaleur sans dimension à l'intérieur du condenseur	-
U^*oc	Coefficient de transfert de chaleur sans dimension à l'extérieur du condenseur	-
WBT	Température humide	°C
WNN	Réseau de neurones ondelettes	-
	Lettres latines	
B_1, B_1, B_2	Constantes arbitraire	-
C	Concentration volumétrique	%
Cp	Capacité calorifique à pression constante	J/°K
D_1, D_2, D_e,	Diamètres	M
D_i	Coefficient de diffusion de l'espèce *i*	Kg/m^3 s
f	Facteur de friction	-
F_{md}	Taux de déposition de solide par unité de surface	Kg m^2/s
F_{mr}	Taux de réentraînement	Kg m^2/s
Gr	Nombre de Grachof	-
g	Accélération de la pesanteur	m/s^2
h'	Hauteur du dépôt solide	m
h	Coefficient de transfert de chaleur	W/m^2 °K
j	Facteur Colburn	-
$\boldsymbol{j}_{li}$	Flux diffusif massique de l'espèce *i*	Kg/m^2 s
k_{diff}	Constante de diffusion	m/s
k_{diss}	Coefficient de transport	m/s
k_r	Coefficient cinétique de réaction	mol/m^2 s
k_{react}	Constante de réaction	m/s
L	Domaine fluide	-
$\dot{m}_{ref}$	Débit massique de réfrigérant	Kg/s
N	Ordre de réaction	-
N_h	Nombre de neurones dans la couche cachée	-
N_p	Nombre de neurones dans la couche d'entrée	-
n_l	Normale sortante liquide	-
Nu	Nombre de Nusselt	-
Ph	Potentiel hydrogène	-
Pr	Nombre de Prandtl	-
Δp	Chute de pression	Pa
$\dot{Q}$	Taux de transfert de chaleur	%
Q	Flux de chaleur imposé par unité de surface	W/m^2
R	Coefficient de corrélation	-
R^2	Coefficient de détermination	-

R_f	Résistance d'encrassement	m² °K/W
R_{f0}	Résistance d'encrassement	m² °K/W
r_i	Taux d'accroissement massique de l'espèce *i* par unité de volume	Kg/m³ s
r_{li}^{Σ}	Taux massique de production	Kg/m² s
r_s^{Σ}	Taux massique de disparition	Kg/m² s
S	Domaine solide	-
t	Temps	s
T	Température	°C
T_{ref}	Température de réfrigérant	°C
ΔT	Différence de température	°C
U	Coefficient de transfert de chaleur	W/m² °K
$\boldsymbol{v_l}$	Vitesse massique de la phase liquide	m/ s
$\boldsymbol{v_l}$	Vitesse de la phase solide	m/s
W	Vitesse de l'interface liquide dépôt	m/s
W_{ij}	Poids synaptiques entrela couche cachéeet la couche de sortie	-
Σ	Interface	-
ρ_{li}^{Σ}	Constante de diffusion	mol/m² s
ρ_{li}^{sat}	Concentration à saturation	mol/m² s

Indices

a	Air	-
ab	Ambiant	-
c	Critique	-
con	Convective	-
CT	Tour de refroidissement	-
f_0	Encrassement	-
h	Couche cachée	-
i	Couche d'entrée	-
i	Constituant liquide	-
ref	Réfrigérant	-
s	Coquille	-
sur	Surface	-
th	Thermique	-
w	Eau	-
o	Couche de sortie	-
min	Minimal	-
max	Maximal	-

Exposants

exper	Valeur expérimentale	-
f	Au-dessus du dépôt	-
in	En entrée	-
pred	Valeur prédite	-

sat	A saturation	-
Σ	Interface liquide-dépôt	-
0	Valeur initiale constante	-
	Lettres grecques	
σ	Résistance du dépôt au cisaillement	W/m^2
τ_s	Contrainte tangentielle exercée sur le dépôt	Pa
λ	Conductivité thermique	W/m°K
λ_s	Conductivité thermique du solide	W/m°K
ρ	Densité	Kg/m^3
υ	Viscosité cinématique	Kg m/s
μ_l	Viscosité dynamique du liquide	Pa s
ρ_s	Masse volumique du dépôt solide	Kg/m^3
ρ_l	Masse volumique du liquide	Kg/m^3
ε	Efficacité	%
η	Rendement	%
$\eta^* c$	Efficacité thermique globale sans dimension	-
$\boldsymbol{\alpha}$	diffusivité thermique	-
$\boldsymbol{\beta}$	Angle de spirale	°

N° Tableau	Description	Page
	Chapitre I : Généralités sur le phénomène d'encrassement dans les échangeurs de chaleur	
I.1	Facteurs d'encrassement typiques	**14**
	Chapitre II : Etat de l'art sur la modélisation de l'encrassement des échangeurs de chaleur	
II.1	Etudes rapportées pour l'analyse thermique des échangeurs de chaleur	**47**
	Chapitre III : Contribution à la modélisation de l'encrassement des échangeurs de chaleur	
	Contribution Préliminaire 1 : Application par réseau de neurones artificiel et par machine à vecteur de support pour prédire l'encrassement des échangeurs de chaleur	
III.1.1	Gamme de variables	**63**
III.1.2	Performances statistiques de RNA	**65**
III.1.3	Performances statistiques de SVM	**67**
III.1.4	Paramètres statistiques obtenus pour le modèle RNA	**70**
	Contribution 2 : Contribution à la modélisation de la résistance à l'encrassement dans l'échangeur-condenseur par réseau de neurones artificiels direct et inverse	
III.2.1	Gamme de variables adimensionnelles	**79**
III.2.2	Exemple de calcule pour une température $T_{(eau\ de\ mer)} = 15°C$	**80**
III.2.3	Structure du RNA	**83**
III.2.4	Performances statistiques du modèle RNA	**84**
III.2.5	Comparaison de 14 algorithmes de rétro-propagation avec 30 neurones dans la couche cachée	**88**
III.2.6	Paramètres statistiques obtenus pour le modèle RNA	**92**
III.2.7	Erreur entre les entrées expérimentales et calculée par RNAi	**94**
III.2.8	Résultats de notre modèle par rapport à divers modèles similaires	**95**
	Contribution3 : Une Application du réseau de neurone artificiel (RNA-MLP) pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides MgO-eau et CuO-eau	
III. 3.1	Gamme des variables	**102**
III. 3.2	Performances statistiques du modèle RNA	**105**
III. 3.3	Les valeurs de poids et de biais de chaque couche déterminées à l'aide du réseau RNA-MLP optimal.	**113**

N° Figure	Description	N° Page
	Chapitre I : Généralités sur le phénomène d'encrassement dans les échangeurs de chaleur	
I.1	Evolution des températures du fluide chaud et du fluide froid le long d'un échangeur à co-courant	**7**
I.2	Evolution des températures du fluide chaud et du fluide froid le long d'un échangeur à contre-courant	**8**
I.3	Schéma de deux types d'échangeurs à courants croisés	**9**
I.4	Echangeur de chaleur coaxiale à double tube	**10**
I.5	Evolution de la résistance d'encrassement en fonction du temps	**11**
I.6	Répartition de la température sur les surfaces encrassées de l'échangeur de chaleur	**15**
I.7	Schéma de la centrale nucléaire REP	**16**
I.8	Répartition par type de produits laitiers en 2017 (Source : " L'économie laitière en chiffres", 2018,)	**17**
I.9	Echangeur sale et propre	**18**
I.10	Dépôt de forte épaisseur dans un tube de surchauffeur de chaudière	**20**
I.11	**a)** dépôts de carbonate de calcium provenant de tuyaux en PVC d'eau potable; **b)** Calcium de carbonate sur les canalisations des eaux usées en PVC; **c)** carbonate de calcium sur les tuyaux en PVC utilisés dans la pasteurisation du lait; **d)** Phosphate de calcium sur des tubes en acier inoxydable utilisés pour la pasteurisation du lait	**20**
I.12	Corrosion dans un tube	**21**
I.13	Exemples de dépôts formés suite à un traitement thermique des aliments : **a)** adsorption d'une monocouche de protéine, **b)** cristallisation, **c)** dépôt protéique avec inclusion de minéraux, **d)** dépôt minéral avec inclusions protéiques	**23**
	Chapitre II : Etat de l'art sur la modélisation de l'encrassement des échangeurs de chaleur	
II.1	Evolution du nombre d'articles publiés sur la modélisation de l'encrassement des échangeurs de chaleur	**29**
II.2	Représentation schématique de la configuration considérée	**30**
II.3	Mécanismes de déposition et de réentraînement	**31**
II.4	Représentation schématique de l'encrassement dans le cas d'un liquide	**32**
II.5	Profils de concentration au voisinage du dépôt solide	**33**
II.6	Principe de la croissance fictive	**35**
II.7	Comparaison entre la résistance d'encrassement mesurée expérimentalement et prédite par les simulations, à deux concentrations en calcium	**38**
II.8	Etapes de la procédure de modélisation neuronale	**41**
II.9	Applications de l'RNA pour l'analyse des échangeurs de chaleur	**52**
	Chapitre III : Contribution à la modélisation de l'encrassement des échangeurs de chaleur	
	Contribution Préliminaire 1 : Application par réseau de neurones artificiel et par machine à vecteur de support pour prédire l'encrassement des échangeurs de chaleur	
III.1.1	Organigramme des processus de formation RNA	**59**
III.1.2	Schéma d'un réseau de type MLP	**61**
III.1.3	Graphe d'analyse de régression RNA entre l'expérimental et prédit de la résistance à l'encrassement adimensionnel	**67**
III.1.4	Graphe d'analyse de régression SVM entre l'expérimental et prédit de la résistance à l'encrassement adimensionnel	**69**
III.1.5	Importance relative (%) des variables d'entrée sur la valeur de la résistance à l'encrassement calculée	**70**
III.1.6	Interface MATLAB pour une résistance à l'encrassement adimensionnelle	**71**
	Contribution 2 : Contribution à la modélisation de la résistance à l'encrassement dans l'échangeur-condenseur par réseau de neurones artificiels direct et inverse	
III.2.1	Structure de l'RNA de rétro-propagation à rétroaction à trois couches construit pour prédire le RE	**77**
III.2.2	Apprentissage avec le diagramme fonctionnel TRAINLM	**84**
III.2.3	Tracé entre la résistance à l'encrassement adimensionnelle expérimentale et RNA prédit pour l'ensemble de données d'apprentissage, l'ensemble de données de test, l'ensemble de données de validation et pour l'ensemble de données totales.	**86**
III.2.4	Effet du nombre de neurones dans la couche cachée sur l'erreur relative absolue du réseau de neurones	**89**

III.2.5	Tracé entre le réseau expérimental et neuronal prédit de la résistance à l'encrassement	**89**
III.2.6	Importance relative (%) des variables d'entrée sur la valeur de la résistance à l'encrassement calculée	**90**
III.2.7	Interface MATLAB pour une résistance à l'encrassement sans dimension	**91**
	Contribution 3 : Une Application du réseau de neurone artificiel (RNA-MLP) pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides MgO-eau et CuO-eau	
III.3.1	Architecture du modèle RNA-MLP proposé pour prédire le RE	**103**
III.3.2	Résistance à l'encrassement expérimentale vs prévue (tous les ensembles de données)	**106**
III.3.3	Représentation graphique des valeurs résiduelles calculées de la résistance à l'encrassement FR à partir du modèle RNA-MLP par rapport à leurs valeurs expérimentales pour les ensembles d'apprentissage, de test et de validation	**106**
III.3.4	Distribution de tous les ensembles de données (a, b, c et d) entre l'expérimentale et RNA-MLP prévue de la résistance à l'encrassement par rapport aux paramètres d'entrée	**109**
III. 3.5	L'effet du nombre de neurones pour MSE et R^2	**110**
III.3.6	L'effet de l'algorithme d'apprentissage pour MSE et R^2	**110**
III.3.7	Comparaisons de la prédiction RNA de RE avec les données expérimentales de nano-fluides (CuO-eau) et corrélations empiriques dans l'échangeur de chaleur	**111**
III.3.8	Importance relative (%) des variables d'entrée sur la valeur de la résistance à l'encrassement calculée	**112**
III.3.9	Interface MATLAB pour la résistance à l'encrassement	**114**

Introduction générale

Dans les sociétés industrielles, l'échangeur de chaleur est un élément essentiel de toute politique de maîtrise de l'énergie et donc, par voie de conséquence, de protection de l'environnement. Une grande part de l'énergie thermique, [1] utilisée dans les procédés industriels transite au moins une fois par un échangeur de chaleur, aussi bien dans les procédés eux-mêmes que dans les systèmes de récupération de l'énergie thermique de ces procédés. Ils sont utilisés principalement dans les secteurs de l'industrie (chimie, pétrochimie, sidérurgie, agro-alimentaire, production d'énergie, etc.), du transport (automobile, aéronautique), mais aussi dans le secteur résidentiel et tertiaire (chauffage, climatisation, etc.). Ils constituent donc un des dispositifs clé du thermicien, et sont un composant quasi inévitable dans la maîtrise de l'énergie, [2]. Compte tenu de leurs multiples utilisations, les difficultés rencontrées par les utilisateurs d'échangeurs de chaleur sont diverses et variées. Toutefois, un des principaux problèmes de fonctionnement auxquels ils se heurtent a trait aux phénomènes d'encrassement. En effet, l'encrassement reste encore, de nos jours, l'un des phénomènes le moins compris et le moins prédictible de l'industrie.

Les principaux problèmes rencontrés par les utilisateurs d'échangeurs thermiques ont relation avec les phénomènes d'encrassement, de corrosion, de vibrations et de tenue mécanique. Malgré tout, un certain nombre d'études publiées, [3-6] montre que l'encrassement reste au premier rang des préoccupations des industriels du secteur des équipements de transferts thermiques. Le couplage encrassement – dégradation des échanges thermiques a de fortes répercutions sur la rentabilité de l'opération. Les coûts liés à l'encrassement des échangeurs avoisinent les 700 millions d'euros par an, [7]. Ces coûts intègrent les dépenses liées, d'une part, au dimensionnement (surdimensionnement de la surface d'échange à mettre en œuvre, incorporation d'équipements de nettoyage) à hauteur de 20% et, d'autre part, au fonctionnement (perte de production, diminution du transfert, frais de maintenance et nettoyage) à hauteur de 80%. Malgré les efforts considérables déployés depuis les premiers travaux de Kern & Seaton, [8] en 1959, l'encrassement demeure encore un phénomène bien mal compris où l'empirisme reste le moyen le plus couramment utilisé. En effet, la large gamme d'écoulements et la panoplie des conditions industrielles existantes contribuent grandement à la méconnaissance du phénomène.

Les recherches sont actuellement menées sur deux fronts, totalement différents mais néanmoins complémentaires. Le premier concerne la détection de l'encrassement,

et le second, concerne les produits et appareillages permettant le nettoyage de tels dépôts.

Le problème commun des échangeurs de chaleur

Un des problèmes majeurs que l'on rencontre dans l'utilisation des échangeurs de chaleur est l'encrassement qui sous sa forme la plus générale, peut être défini comme l'accumulation d'éléments solides indésirables sur les surfaces solides, [9]. Ce phénomène provoque, entre autres, une surconsommation d'énergie due à un écart de température supérieur à celui nécessaire avec éventuellement la surcharge des pompes et/ou des ventilateurs associer au processus. Selon l'étude établie par, [10] il existe trois grands types d'encrassement :

- La corrosion,
- L'encrassement biologique,
- L'encrassement par réaction chimique.

Quel que soit le phénomène d'encrassement considéré, les méthodes classiques pour la détection d'encrassement, [11] sont :

- L'examen du coefficient de transfert thermique (ou efficacité),
- L'observation simultanée des chutes de pression et des débits massiques,
- Les mesures de température,
- La pesée des plaques de l'échangeur de chaleur.

But de thème

La formation et l'élimination des dépôts à la surface des équipements de transformation mettent en jeu une combinaison de phénomènes complexes qui ne sont pas encore tous expliqués. Une des principales lacunes concerne la relation entre les réactions chimiques, les transferts de chaleur et de quantité de mouvement et la croissance puis l'élimination d'un dépôt.

Lors de ces changements de température, on observe fréquemment une formation non souhaitée de dépôt sur les parois de l'équipement. Le type du dépôt est spécifique à chaque secteur de l'industrie et aux conditions opératoires utilisées pour la transformation.

Ceci est le cas où la modélisation de l'encrassement dans l'échangeur de chaleur joue un rôle important, Il est donc nécessaire de développer des modèles basant sur les données de l'analyse thermique des échangeurs de chaleur.

Effectivement, au cours des cinq dernières décennies, il y a eu de nombreuses tentatives par les chercheurs avec différentes techniques, parmi eux, les modèles mathématiques linéaires, les modèles des fonctions non linéaires, les modèles de réseau de neurones artificiels et les modèles optimisés.

Dans ce contexte, il sera l'objet de notre thèse de chercher pour offrir une contribution à la modélisation de l'encrassement des échangeurs de chaleur. La thèse englobe trois chapitres:

Le premier c'est un rappel sur certaines connaissances de base concernant le Phénomène d'encrassement, Notions sur les échangeurs, Modes d'écoulement, Encrassement des surfaces d'échanges dans l'industrie thermiques, Encrassement des surfaces d'échanges dans l'industrie laitier, Catégories et types d'encrassement, Nature du dépôt, Processus fondamentaux de l'encrassement.

Le second chapitre présente un examen complet et détaillé de l'état de l'art concernant les recherches qui ont une relation avec le thème, et résume le développement récent des approches de modélisation de l'encrassement des échangeurs de chaleur.

Le troisième et le dernier chapitre sera consacré à la modélisation neuronale, et comporte trois contributions, la première (préliminaire) traite d'une façon détaillée la méthodologie d'optimisation du modèle neuronal et un modèle de machine à vecteur de support pour la prédiction de la résistance à l'encrassement dans un échangeur à contre-courant tandis que la deuxième met l'accent sur la recherche des paramètres adimensionnelles d'un modèle neuronal direct et inverse optimal qui est valable pour tous les échangeurs de chaleur. La troisième contribution neuronale (RNA-MLP) est basée sur les nano-fluides (MgO-eau et CuO-eau) pour une base de données de 375 points validée et comparée par rapport aux corrélations proposées pour la prédiction de la résistance à l'encrassement de l'échangeur de chaleur.

Enfin, nous terminons par une conclusion générale qui rassemble les principaux résultats obtenus, dégage les points forts de notre recherche de l'analyse thermique des échangeurs de chaleur (résistance à l'encrassement) et énonce des perspectives de recherche.

Chapitre I
Généralités sur le phénomène d'encrassement dans les échangeurs de chaleur

I.1. Introduction

Les procédés utilisés dans l'industrie demandent souvent que les fluides traités soient réchauffés ou refroidis avec ou sans changement de phases au cours des diverses opérations auxquelles ils sont soumis. La chaleur mise en œuvre représente une importante dépense d'énergie dont il est nécessaire de récupérer la plus grande quantité possible. De ce fait les échangeurs de chaleur constituent des appareillages importants.

Il est possible de caractériser un échangeur de chaleur par :

- La nature des matériaux qui le constituent (métallique, verre, plastique, graphite).
- La nature des fluides de transfert (liquide, gaz, mélange de plusieurs phases, solides pulvérisant).
- La conception de l'échangeur.

I.2. Notions sur les échangeurs

Un échangeur de chaleur est un équipement qui permet d'assurer un transfert de chaleur d'un fluide chaud à un fluide froid. Le même fluide peut conserver son état physique (liquide ou gazeux) ou se présenter successivement sous les deux phases : c'est le cas des condenseurs ; évaporateurs ; rebouilleurs ou des tours de refroidissement, [12].

En principe, pour les échangeurs les plus couramment utilisés dans l'industrie, les deux fluides s'écoulent dans des espaces séparés par une paroi ou cloison à faible inertie thermique au travers de laquelle les échanges se font par conduction. En effet, la chaleur que l'un des fluides cède à la paroi par convection le long de la surface de contact est transférée par conduction et, est cédée à l'autre fluide par convection le long de l'autre face. Le rayonnement n'intervient de manière significative que s'il existe des différences de température très importantes entre un fluide semi- transparent et la paroi.

De par leurs différentes applications, les caractéristiques des échanges se situent dans une gamme très étendue en encombrement, en puissance échangée, en pression et en température. Les exigences de fonctionnement, les différentes normes imposées par le législateur pour la conception de tels appareils, les technologies ainsi que les matériaux utilisés sont inévitablement variés et difficilement comparables, [13].

Il devient donc difficile d'établir une classification rigoureuse sans faire le choix incontestablement restrictif d'un critère, le plus souvent ; les échangeurs de chaleur sont classifiés selon la configuration d'écoulement des fluides considérés et selon leur type de construction.

I.2.1. Modes d'écoulement des deux fluides

On peut distinguer 3 modes d'écoulement différents

I.2.1.1. Ecoulement co-courants (Ecoulement des deux fluides parallèles et de même sens)

Il s'agit d'échangeurs dits à co-courants ou la température de fluide froid ne peut pas être supérieure à la température de sortie du fluide chaud. Les températures des fluides évoluent pendant leur traversée longitudinale de l'échangeur, à moins que l'un des fluides ne subisse un changement de phase.

La **figure I.1** donne l'évolution qualitative de ces températures le long d'un échangeur tubulaire à co-courants très simple, la longueur de l'échangeur a été portée en abscisse, les températures sont repérées à l'aide d'indices e signifiant entrée et s sortie, [14], c désignant le fluide chaud et f le fluide froid.

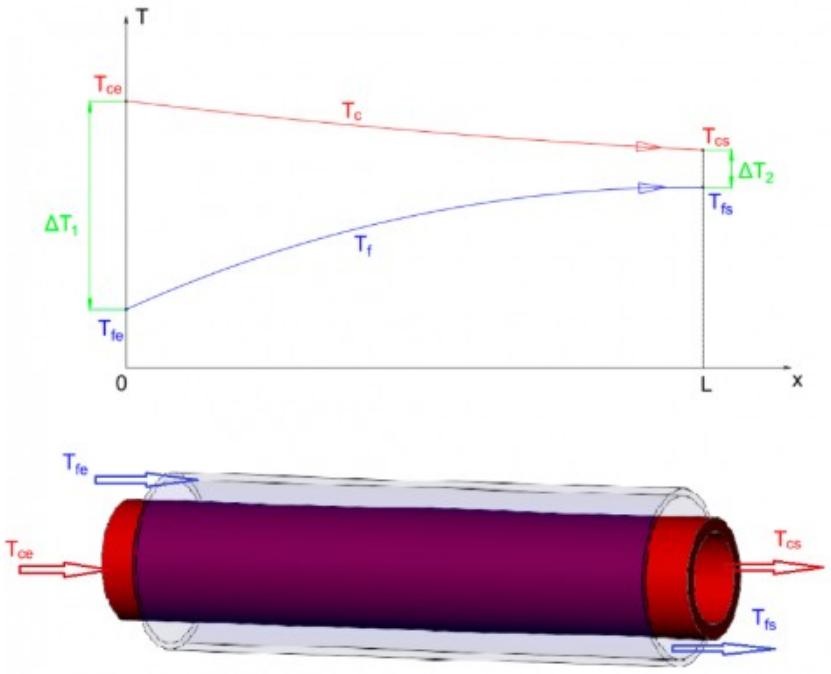


Figure I.1 : Evolution des températures du fluide chaud et du fluide froid le long d'un échangeur à co-courant, [14].

I.2.1.2. Ecoulement contre-courants (Ecoulement des fluides parallèles mais de sens contraires)

Il s'agit d'échangeurs à contre courants ou la température du fluide froid peut dépasser la température de sortie du fluide chaud. Cette disposition est l'une des plus favorables pour l'échange thermique.

L'avantage de l'échangeur à contre-courant sur l'échangeur à co-courant est de nécessiter, pour un même flux de chaleur, des surfaces d'échanges plus faibles.

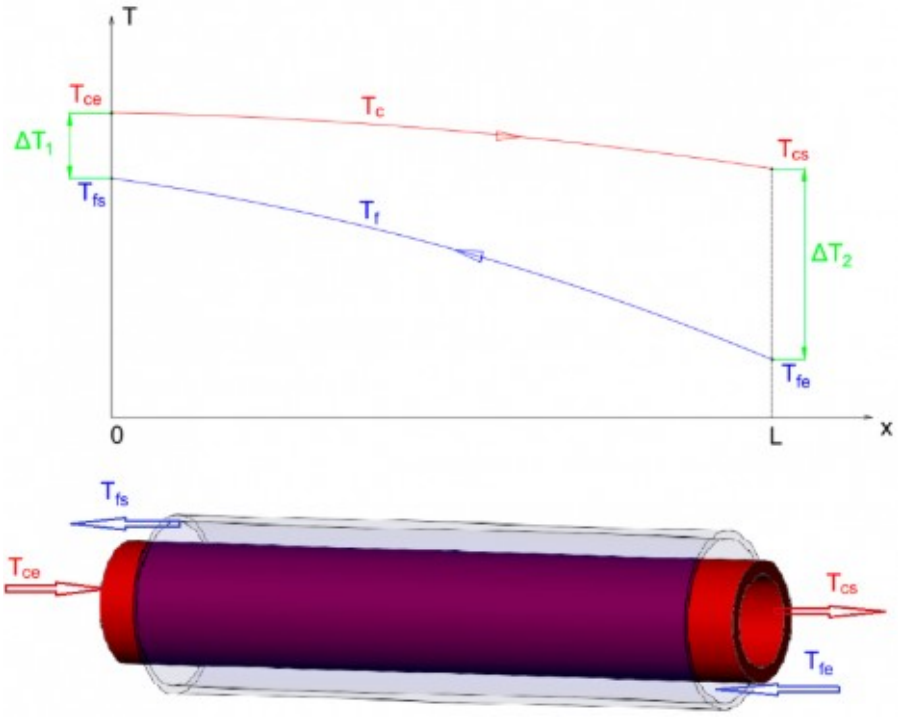


Figure I.2 : Evolution des températures du fluide chaud et du fluide froid le long d'un échangeur à contre-courant, [14].

I.2.1.3. Ecoulement des fluides croisés avec ou sans brassage

Les deux fluides s'écoulent perpendiculairement l'un à l'autre, le fluide non brassé est canalisé : c'est celui dont la veine est divisée entre plusieurs canaux parallèle distincts et de faible section. L'autre fluide circule librement entre les veines et peut être considéré comme partiellement brassé du fait des tourbillons générés par les tubes. Le brassage a pour effet d'homogénéiser les températures dans les sections droites de la veine fluide. Sans cela, les températures varient non seulement avec la direction de l'écoulement, mais aussi dans la section de veine. Une représentation schématique d'échangeur à courant croisés est donnée par la **figure I.3.**

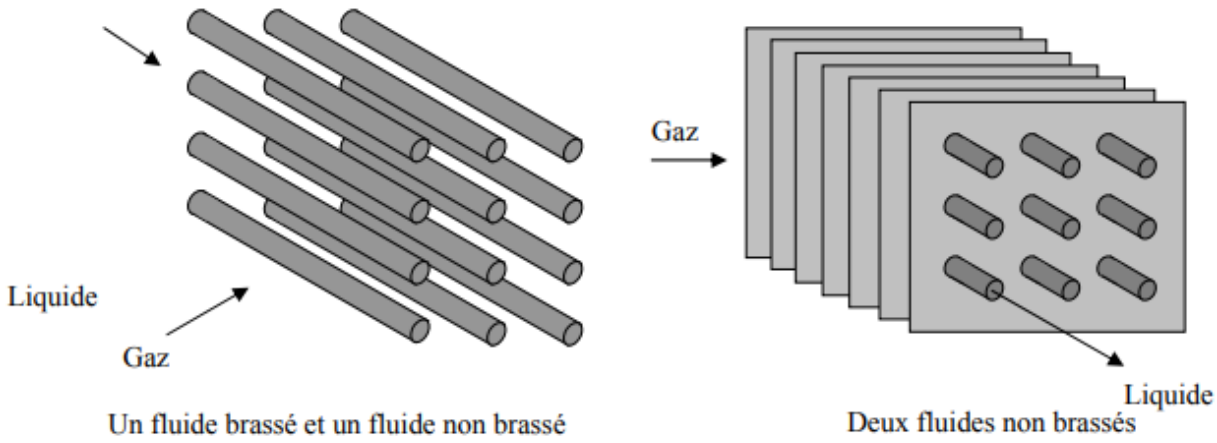


Figure I.3 : Schéma de deux types d'échangeurs à courants croisés, [14].

I.3.Echangeurs tubulaires

Ils présentent un certain nombre d'avantages : en particulier ils sont faciles à fabriquer, relativement bon marché, de maintenance aisée et surtout ils peuvent être utilisés à des pressions élevées et à de fortes températures. Leur robustesse et leur fiabilité contrebalancent leur encombrement, [15].

On distingue, le plus souvent, les catégories suivantes :

- Les échangeurs monotubes pour lequel le tube est placé dans un réservoir.
- Les échangeurs coaxiaux pour lesquels les tubes sont le plus souvent cintrés.
- Les échangeurs multitubulaires qui existent sous 4 formes.

Le type d'échangeur de chaleur le plus simple et le plus courant est l'échangeur de chaleur tubulaire. Les échangeurs de chaleur tubulaires sont constitués de tubes circulaires. Un fluide s'écoule à l'intérieur des tubes et l'autre s'écoule à l'extérieur des tuyaux. Les diamètres des tubes, le nombre de tuyaux, la longueur du tube, le pas des tuyaux et l'ensemble des conduites peuvent être modifiés.

I.3.1. Echangeur de chaleur à double tube

Un échangeur coaxial constitué de deux tubes concentriques et supposons que le fluide 1 circule dans le tube intérieur de diamètre D_1 et que le fluide 2 circule dans l'espace annulaire de diamètres D_2 et D_e ; la paroi d'échange est alors constituée par le tube intérieur, [16] **figure I.4.**

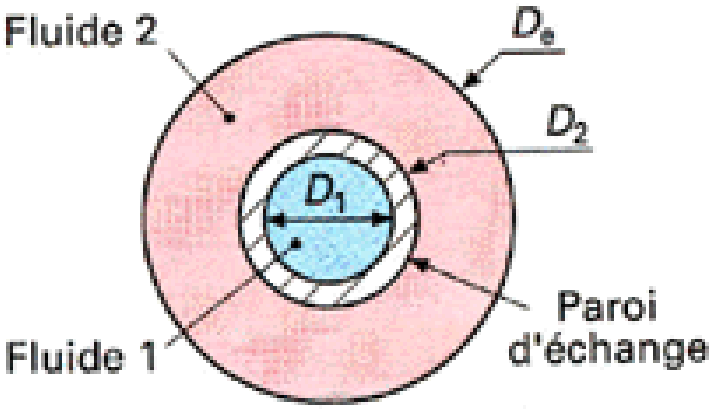


Figure I.4 : Echangeur de chaleur coaxiale à double tube, [16].

I.3.2. Analyse thermique des tuyaux intérieurs

Le but de l'analyse thermique est de déterminer le coefficient de transfert de chaleur dans le tuyau intérieur. Le premier calcul à effectuer est de déterminer le nombre de Reynolds pour déterminer si le flux est laminaire ou turbulent à l'intérieur du tuyau. Pour calculer le nombre de Reynolds, il est essentiel d'avoir accès aux différentes tables de propriétés des fluides divers qui s'écoulent dans les conduites d'échangeur de chaleur. Nous devrions connaître les propriétés fluides suivantes, [17] :

- Densité, ρ
- Viscosité, υ
- Capacité calorifique à pression constante, cp
- Conductivité thermique, λ

I.4. Cinétique de l'encrassement

L'étude de l'évolution de l'encrassement en fonction du temps peut être contrôlée par trois paramètres différents. Soit par la mesure de l'épaisseur du dépôt formé sur la plaque, soit par la masse du dépôt par unité de surface, ou soit par l'évolution de la température de la paroi. Ces paramètres font intervenir la résistance d'encrassement désigné par $\boldsymbol{R_d}$.

On désigne par $\boldsymbol{m_d}$ la masse déposée par unité de surface, d'épaisseur $\boldsymbol{e_d}$, de conductivité thermique $\boldsymbol{\lambda_d}$ et de masse volumique $\boldsymbol{\rho_d}$.

L'épaisseur de la couche encrassante est calculée comme étant la masse totale déposée par unité de surface divisée par la densité de la couche encrassante [68].

$$\boldsymbol{e_d} = \frac{\boldsymbol{m_d}}{\boldsymbol{\rho_d}} \qquad \text{(I.1)}$$

Après que l'épaisseur totale a été déterminée et en supposant que la conductivité thermique est constante. La résistance d'encrassement peut être alors calculée comme suit:

$$\boldsymbol{R_d} = \frac{\boldsymbol{m_d}}{\boldsymbol{\rho_d \lambda_d}} = \frac{\boldsymbol{e_d}}{\boldsymbol{\lambda_d}} \quad \text{(I.2)}$$

Le bilan de l'encrassement peut s'exprimer par la différence entre les densités de flux massiques de dépôt $\emptyset_d$ et de réentraînement $\emptyset_r$ [62], soit :

$$\frac{\boldsymbol{dm_d}}{\boldsymbol{dt}} = \emptyset_d - \emptyset_r = \frac{\boldsymbol{\rho_d \lambda_d dR_d}}{\boldsymbol{dt}} \quad \text{(I.3)}$$

La résistance d'encrassement sera donnée par :

$$\frac{\boldsymbol{dR_d}}{\boldsymbol{dt}} = \frac{\mathbf{1}}{\boldsymbol{\lambda_d \rho_d}}(\emptyset_d - \emptyset_r) \quad \text{(I.4)}$$

I.4.1. Modèles d'évolution de l'encrassement

L'évolution du dépôt encrassant est représentée par sa résistance (équations (I.2) et (I.4)). La résistance d'encrassement en fonction du temps présente différents types d'évolutions [18], comme le montre la **figure I.5**.

Kern et Seaton [62] ont proposé un modèle simple décrivant l'évolution de la résistance d'encrassement telle que :

$$\frac{\boldsymbol{dR_d}}{\boldsymbol{dt}} = \emptyset_d - \emptyset_r \quad \text{(I.5)}$$

Où $\emptyset_d$ est le flux massique de dépôt considérée comme constante, et $\emptyset_r$ est le fluxmassique de réentraînement qui est proportionnelle à $\boldsymbol{R_d}$.

Pour certaines applications on peut observer la présence d'une période d'initiation ou un temps d'induction avant que le dépôt apparaisse et évolue suivant une des courbes de la **figure I.5** [62].

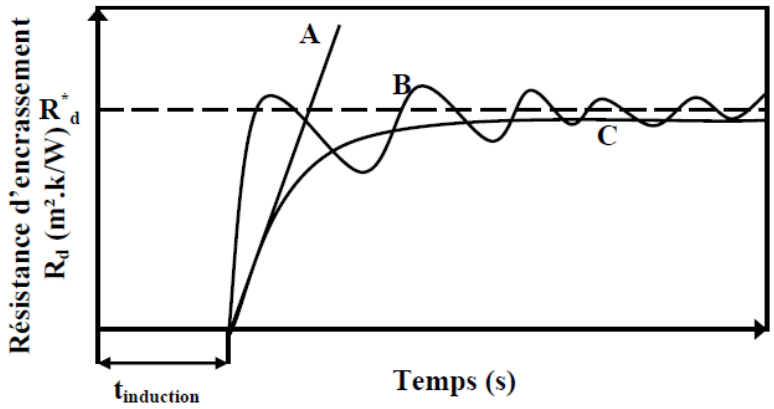


Figure I.5 : Evolution de la résistance d'encrassement en fonction du temps, [18].

Évolution de la courbe A :

C'est le cas d'un encrassement linéaire, ou le dépôt encrassant évolue instantanément au cours du temps. Ce type d'évolution est obtenu après intégration de l'équation (I.5) en considèrent que le taux de déposition est constant et en négligent le taux d'enlèvement. L'évolution A dans la **figure I.5** est une droite qui s'exprime sous la forme :

$$\boldsymbol{R_d = A.t} \qquad \text{(I.6)}$$

Où *"A"* représente le taux d'accroissement de la résistance d'encrassement $\boldsymbol{R_d}$.

Cette relation est généralement caractéristiques des dépôts durs et adhérents et indique que la vitesse de dépôt $\emptyset_d$ est constante et qu'il n'y a pas de réentraînement.Elle peut être également observée lorsque la différence entre les densités de flux massiques de dépôt et de réentraînement $(\emptyset_d - \emptyset_r)$ est constante. Certains échangeurs possèdent une caractéristique d'encrassement de cette forme. C'est notamment le cas de certains évaporateurs, [62].

Évolution de la courbe B :

La courbe "B" illustre mieux le cas réel, le réentraînement d'une partie du dépôt modifie de manière très sensible l'évolution de la résistance d'encrassement en fonction du temps [62].

Dans la pratique, le réentraînement d'une partie du dépôt par "paquets" modifié de manière très sensible l'évolution de la résistance d'encrassement en fonction du temps. On obtient alors une évolution en "dents de scie" (courbe "B" de la **figure I.5**).

L'apparition de ce mode sous des conditions stables d'écoulement, de température et de concentration, implique un détachement répétitif correspondant à un affaiblissement périodique du dépôt au-dessous d'une certaine valeur critique du flux net de déposition. Un tel affaiblissement peut être dû à un changement de structure cristalline, une dégradation chimique, un développement de contraintes thermiques ou un empoisonnement progressif des microorganismes dans un biofilm.

Le fait qu'une couche inférieure se conserve pendant que les couches supérieures de dépôt se détachent sous les forces de vitesse, revient peut être à la coexistence de deux types d'encrassement avec deux différents dépôts. C'est le cas de la formation, l'affaiblissement puis le détachement de biofilms au-dessus d'une couche de dépôt de corrosion, [19].

L'enlèvement périodique peut être aussi causé par une perturbation accidentelle de particules partiellement déposées sur la paroi. C'est, par exemple, le cas de la corrosion en fissures, [20], où la corrosion cesse une fois que la paroi est uniformément encrassée, plutôt qu'un enlèvement continu.

Évolution de la courbe C :

La courbe d'encrassement "C" est de type asymptotique. Elle est obtenue si le taux de déposition est constant et que le taux d'enlèvement soit proportionnel à l'épaisseur de la couche d'encrassement. Il est suggéré que les forces de cisaillements de la couche diminuent ou bien d'autres mécanismes prennent place pour détériorer la stabilité de la couche.

De la même façon, la situation généralement se produit si le dépôt est mou. L'encrassement dans ce cas prend des valeurs asymptotiques.

L'évolution de la courbe "C" et après intégration de l'équation (I.5) entre la condition initiale ($\boldsymbol{t = 0, R_d = 0}$) et n'importe quelle condition ($\boldsymbol{t, R_d}$), conduit à l'équation classique du modèle de, 62] :

$$\boldsymbol{R_d = R_d(1 - e^{-\Omega.t})} \quad \text{(I.7)}$$

Où $\boldsymbol{R_d}$ est la résistance d'encrassement asymptotique et $\boldsymbol{\Omega}$ une constante de temps qui est fonction des propriétés du système.

Ce type de comportement est caractéristique des dépôts fragiles "mou" s'écaillant facilement sous l'influence des forces de cisaillement provoquées par le passage du fluide. Le comportement asymptotique de cette résistance a été observé avec nombreuses fois dans des situations d'encrassement particulaire. Dans la pratique, les courbes expérimentales présentent une évolution en dents de scie due au réentraînement d'une partie du dépôt par paquets.

I.4.2. Facteurs d'encrassement

L'encrassement est fonction du système et de l'équipement utilisé. Les paramètres qui influencent le taux d'encrassement dans un système comprennent : le type de fluide, le type d'échangeur de chaleur, les températures, les vitesses et les matériaux de construction. Le taux d'encrassement réel est différent pour chaque application.

Tableau I.1 : Facteurs d'encrassement typiques, [21].

Eau	Résistance à l'encrassement ($m^2K.W^{-1}$)		Résistance à l'encrassement ($m^2K.W^{-1}$)	
Température de l'eau	**< à 325 K**		**> à 325 K**	
Vitesse de l'eau	**<à 3m/s (x 10^{-4})**	**> à 3m/s (x 10^{-4})**	**< à 3m/s (x 10^{-4})**	**> à 3m/s (x 10^{-4})**
Eau de purge de chaudière	3.52	3.52	3.52	3.52
Condensat	0.88	0.88	0.88	0.88
Eau de tour de refroidissement (traitée)	1.76	1.76	3.52	3.52
Eau de tour de refroidissement (non traitée)	5.28	5.28	0.88	7.04
Eau de ville ou de puits	1.76	1.76	3.52	3.52
Eau de rivière	3.52	1.76	5.28	7.04
Eau de mer	0.88	0.88	1.76	1.76

I.4.3. Corrélations empiriques sur la résistance à l'encrassement

$$\frac{dR_d}{dt} = \frac{1}{\lambda_d \rho_d}(\emptyset_d - \emptyset_r)$$ Kern et Seaton (1959), [62].

$$\frac{dR_d}{dt} = \frac{K_r}{\rho_f \lambda_f}(C_b - C_s)^2 - K_{rem}\frac{\tau}{\rho_f \sigma_f} R_d$$ Mwaba, M. G et al (2006), [81]

$$R_d(t) = \frac{K_3 CV}{\lambda_d K_4 \tau_w}(1 - e^{-K_4 \tau_w t}) = R_d^*(1 - e^{-bt})$$ Müller-Steinhagen, H. (2011), [22]

$$\frac{dR_d}{dt} = \alpha Re^{\beta} exp\left(\frac{-E}{RT_f}\right) - \gamma \tau_w$$ Al-Hallaf, W. A. A. (2013), [23]

$$\frac{dR_d}{dt} = \frac{1}{K_{np}}\left[K_t(C_{b,nf} - C_w) - \frac{B\left(v\sqrt{\frac{f}{2}}\right)^2 m_f}{\Omega}\right]$$ Nikkhah, V et al (2015), [307]

I.5. Encrassement des surfaces d'échanges dans l'industrie thermiques

L'encrassement représente un problème important pour les condenseurs et les échangeurs de chaleur. Tous les circuits industriels refroidis à l'eau douce naturelle et marine sont affectés par le phénomène d'encrassement biologique consistant en la croissance du biofilm et les tassements de plusieurs types d'organismes vivants.

La **figure I.6** illustre comment la distribution de température est affectée par la présence des couches d'encrassement individuelles.

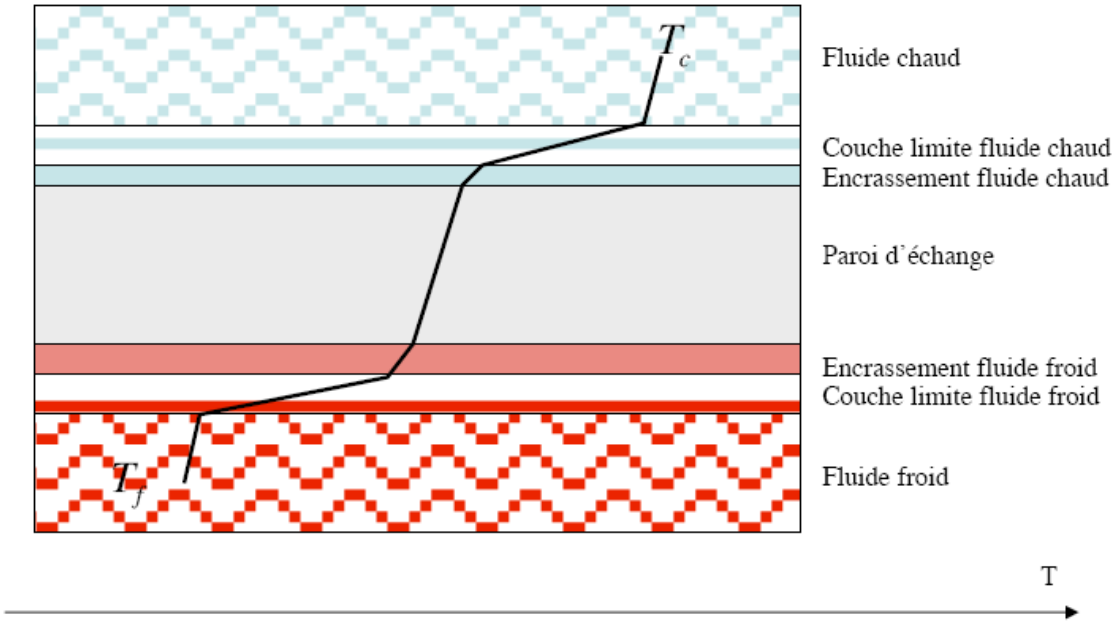


Figure I.6 : Profil de température et les résistances au transfert de chaleur, [22].

I.5.1. Conséquences des phénomènes d'encrassement

Les conséquences des phénomènes d'encrassement viennent du fait que les dépôts d'encrassement augmentent la résistance thermique au flux thermique. Selon la théorie de base, le taux de transfert de chaleur dans l'échangeur dépend de la somme des résistances thermiques entre les deux fluides. L'encrassement sur un ou les deux côtés du fluide ajoute la résistance thermique à la résistance thermique globale et, à son tour, réduit le taux de transfert de chaleur. Simultanément, la résistance hydraulique augmente en raison d'une diminution de la zone d'écoulement libre. Par conséquent, la pression chute et la puissance de pompage augmente. L'augmentation du facteur et de la température d'encrassement de l'eau de mer de refroidissement du condenseur peut avoir un impact sur l'utilisation de la capacité des centrales thermiques dans deux domaines:

Efficacité réduite: l'augmentation de la température environnementale et du facteur d'encrassement réduit l'efficacité thermique d'une centrale thermique,

Charge réduite : pour des températures ambiantes élevées et un facteur d'encrassement, le fonctionnement de la centrale thermique sera limité par une pression maximale possible du condenseur. Le fonctionnement des installations avec eau de refroidissement fluviale ou maritime sera en outre limité par une température maximale autorisée régulée pour l'eau de retour ou par un accès réduit à l'eau, [24].

I.5.2. Impact du changement du facteur d'encrassement et de la température de refroidissement de l'eau de mer sur l'échangeur de chaleur

L'évaluation de l'impact du changement du facteur d'encrassement et de la température de l'eau de mer de refroidissement sur le coefficient de transfert de chaleur global du condenseur est effectuée dans une plage spécifique conçue de température d'eau de mer et de l'encrassement.

La **figure I.7** représente un schéma d'une centrale nucléaire REP. La centrale nucléaire REP typique se compose d'un cycle primaire qui comprend:

- Un réacteur nucléaire,
- Un générateur de vapeur,
- Un pressuriseur,
- Une pompe de refroidissement du réacteur.

Et un cycle secondaire composé d'une :

- Trois turbines à vapeur basse pression,
- Un séparateur d'humidité et réchauffeur,
- Echangeur d'alimentation du dégazeur,
- Deux échangeurs d'alimentation haute pression,
- Trois échangeurs d'alimentation basse pression,
- Condenseur et pompes (pompe d'eau d'alimentation et pompe de condensat).

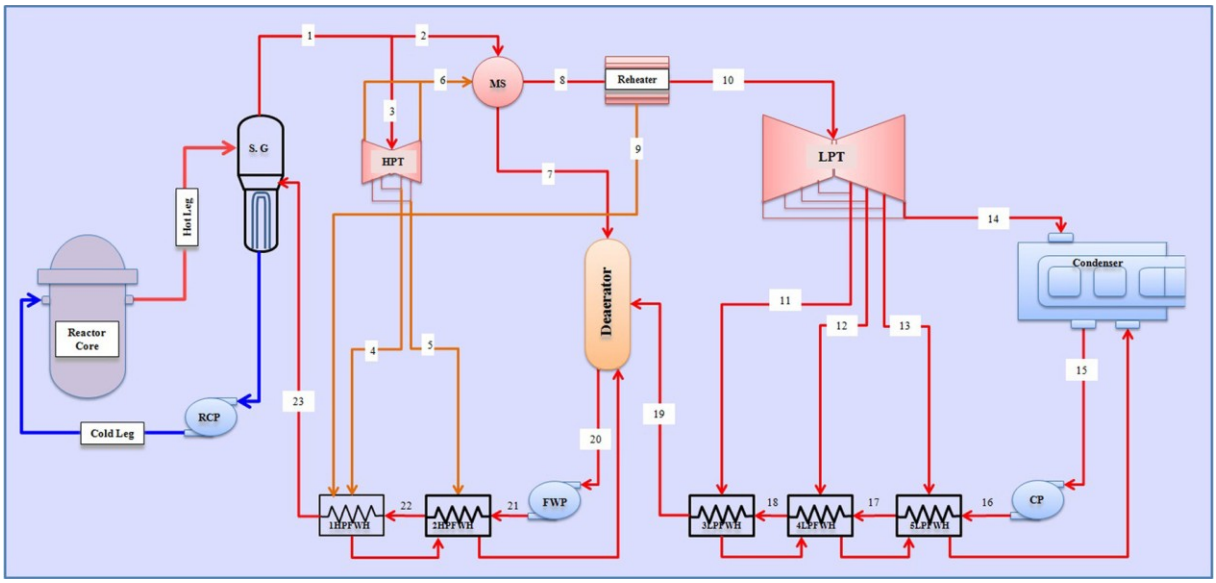


Figure I.7 : Schéma de la centrale nucléaire REP, [25].

I.6 Encrassement des surfaces d'échanges dans l'industrie laitier positionnement et enjeux

I.6.1. Importance du secteur laitier et enjeux de maitriser les encrassements

A titre d'exemple en France la filière laitière affiche un chiffre d'affaires de 30 milliards d'euros en 2018 dont 7 milliards d'euros à l'export. Avec plus de 250 000 emplois (150 000 exploitations et 56 000 industries laitières) répartis sur tout le territoire. En effet, le secteur agricole et agroalimentaire (+11,5 milliards d'euros) est le deuxième secteur contributeur derrière l'industrie aéronautique (+22 milliards d'euros, source : douanes 2011). Le produit lait équivaut à 8,7 milliards d'euros de production en valeur, soit 13% de la production agricole totale (2018).

La répartition de la production de lait de vache en différents produits est présentée sur la **figure I.8**.

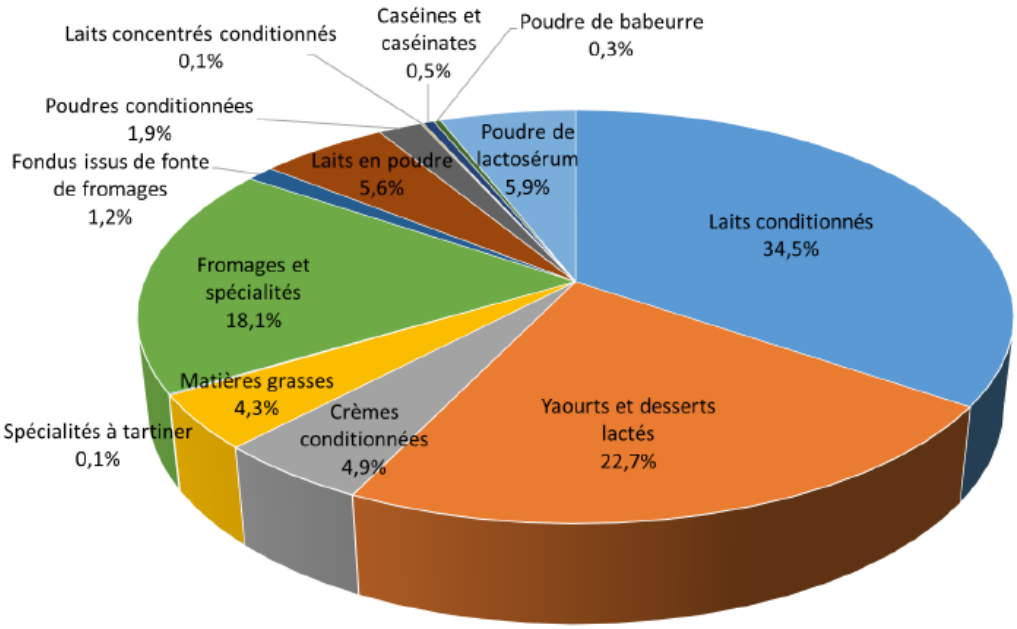


Figure I.8 : Répartition par type de produits laitiers en 2017 (Source : " L'économie laitière en chiffres ", 2018), [26].

I.6.2. Aspect physique de l'encrassement

L'encrassement qui, sous sa forme la plus générale, peut être défini comme l'accumulation d'éléments solides indésirables ou de substances non désirées sur une interface, affecte un grand nombre d'opérations industrielles **figure I.9**.

Ce dépôt qui évolue dans le temps, peut être constitué de cristaux, de sédiments, de résidus biologiques, des produits d'une réaction chimique ou bien encore être la combinaison de plusieurs de ces éléments.

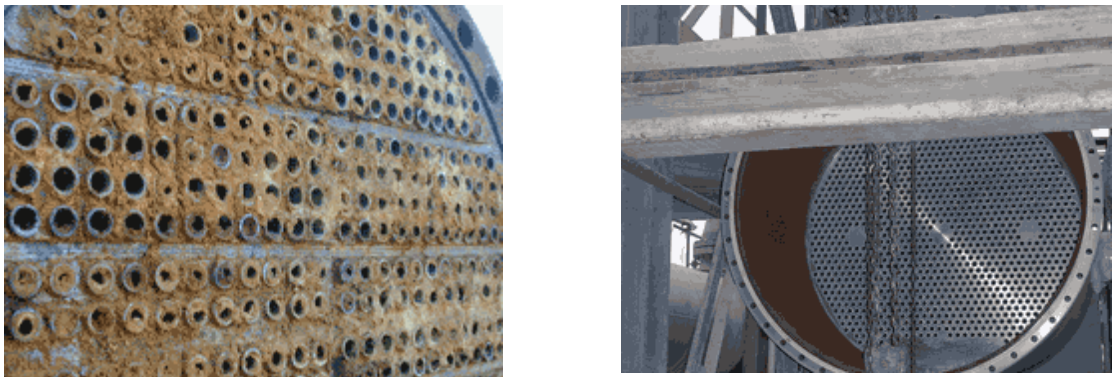


Figure I.9 : Echangeur sale et propre, [27].

Il a été démontré au cours des longues années passées dans la recherche de moyens de lutte contre l'encrassement, que ce dernier était lié aux conditions opératoires, aux propriétés physico-chimiques des fluides mis en jeu, à la géométrie du système ainsi qu'à la nature des surfaces, [28]. La connaissance de l'origine du phénomène est un facteur déterminant pour répondre aux variations de ces paramètres.

I.6.3. Aspect économique et environnemental de l'encrassement

Des efforts considérables sont fournis pour analyser le phénomène d'encrassement. Durant le fonctionnement, l'échangeur de chaleur devient encrassé avec l'accumulation des dépôts d'une ou plusieurs espèces sur les surfaces de transfert de l'échangeur. En conséquence, la résistance thermique augmente, ceci fait baisser les performances de l'échangeur, [29-32]. La couche d'encrassement bloque le passage du fluide et augmente la surface rugueuse, est ainsi réduit le taux de transfert de chaleur.

Les inconvénients économiques de l'encrassement sont attribués à :

- De grosses pertes d'énergie provoquées par l'inefficacité thermique.
- Le coût élevé de maintenance pendant la période de nettoyage des échangeurs.
- De grosses pertes de production durant la période d'arrêt pour le nettoyage.

Les dépenses relatives à toutes les causes d'encrassement, se traduisent par :

- Un surdimensionnement des appareils, en bureau d'études,
- Une dépense d'énergie supplémentaire,
- Le remplacement du matériel corrodé,

- Des coûts d'arrêt d'installation (nettoyage, démontage…).

I.7. Catégories et types d'encrassement

Il est possible de classer l'encrassement selon le mécanisme qui contrôle la vitesse de dépôt, selon les conditions d'utilisations de l'échangeur ou selon le mécanisme dominant, même s'il ne contrôle pas la vitesse de dépôt : pour cela on distingue selon, [33-34].

- Encrassement particulaire,
- Entartrage,
- Corrosion,
- Encrassement biologique,
- Encrassement par réaction chimique,
- Encrassement par solidification,

Mais la plupart des dépôts réels sont le résultat de la combinaison d'au moins deux des types cités, un type peut prédominer et accélérer à la contribution des autres. La plupart des travaux se sont basé seulement sur le type d'encrassement particulaire (phénomène de déposition et de réentraînement), [35].

I.7.1. Encrassement particulaire

La plupart des écoulements, de fluides industriels (liquides ou gazeux) transportent des particules en suspension dont la taille varie d'une fraction de µm à quelques dizaines de µm ; le dépôt est inévitable d'une partie de ces particules sur la surface d'échange, [36], **figure I.10.**

- L'eau de chaudière contenant des produits de corrosion.
- L'eau de tours de refroidissement.
- Les écoulements gazeux pouvant être fortement chargés de particules de poussières.
- Les fumées industrielles de résidus solides de combustion.

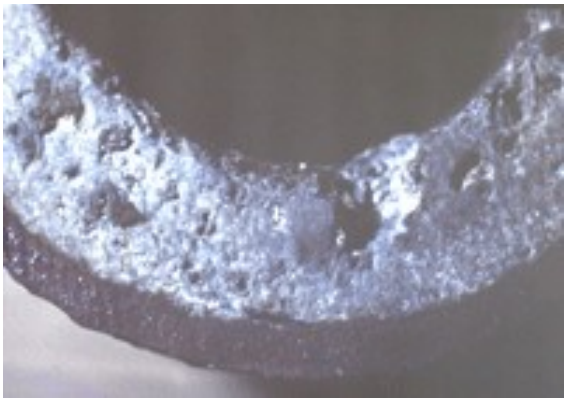


Figure I.10 : Dépôt de forte épaisseur dans un tube de surchauffeur de chaudière, [36].

I.7.2. Entartrage

Il est généralement associé à la production d'un solide cristallin à partir d'une solution liquide, [37]. Il dépend donc fortement de la composition des eaux industrielles. L'entartrage se matérialise par une formation d'incrustations adhérentes et dures sur les surfaces d'échanges généralement métalliques. Pour qu'il y ait entartrage, deux conditions doivent être réunies :

- La limite de solubilité doit être dépassée, c'est à dire qu'il y ait saturation : c'est l'aspect thermodynamique.
- La vitesse de déposition doit être suffisamment rapide : c'est l'aspect cinétique, [38,39]. **figure I.11.**

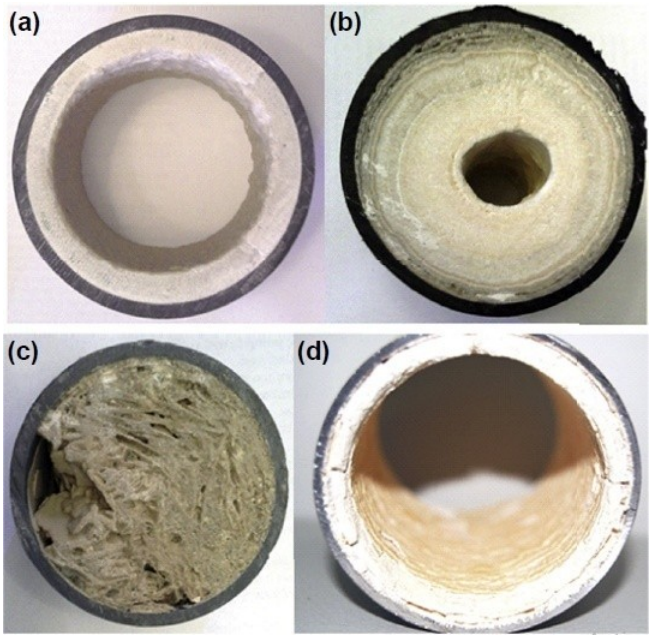


Figure I.11 : a) dépôts de carbonate de calcium provenant de tuyaux en PVC d'eau potable; **b)** Calcium de carbonate sur les canalisations des eaux usées en PVC; **c)** carbonate de calcium sur les tuyaux en PVC utilisés dans la pasteurisation du lait; **d)** Phosphate de calcium sur des tubes en acier inoxydable utilisés pour la pasteurisation du lait, [40].

I.7.3. Corrosion

C'est le résultat d'une réaction chimique ou électrochimique entre la surface de transfert de chaleur et le fluide en écoulement, on distingue :

- La corrosion uniforme caractérisée par une perte d'épaisseur régulière mais dont la vitesse n'est pas forcément proportionnelle au temps.
- La corrosion par piqûres ou l'attaque est limitée à des zones de très petites surfaces ($\approx 1mm^2$).
- La corrosion fissurant à l'échelle microscopique intergranulaire ou transgranulaire.
- La corrosion sélective ou seul un élément d'un alliage subit une attaque sélective, [39], **figure I.12.**



Figure I.12 : Corrosion dans un tube, [39].

L'encrassement par corrosion est un promoteur potentiel pour tous les autres types d'encrassement, les produits de corrosion peuvent servir de germes de nucléation pour des solutions sursaturés, piéger les particules en suspension, servir d'abris pour le développement de micro-organismes et mêmes catalyser certaines réactions, [41].

I.7.4. Encrassement biologique

Il est dû au développement de micro-organismes qui créent un film au contact de la surface d'échange, il peut être causé par trois grands types de micro-organismes: les bactéries, les algues et les champignons, [41].

- Le développement bactérien est dû à un apport nutritif (hydrocarbures, ammoniaques),

- Le développement des algues est dû à la présence d'énergie solaire avec photosynthèse,
- Les champignons se développement avec l'apport de nutriments mais surtout dus aux changements de conditions physiques ambiantes (pH, humidité, température).

I.7.5. Encrassement par réaction chimique

Il est dû à une réaction chimique qui se produit près d'une surface d'échange de chaleur et que les produits solides de la réaction s'y déposent, cette réaction est souvent une polymérisation et il en résulte la formation d'un dépôt de substance de hauts poids moléculaires, [42,43].

I.7.6. Encrassement par solidification

Il s'agit de solidification d'un liquide pur au contact d'une surface d'échange sous refroidie, c'est un sujet de plusieurs études sur les pipes soit théorique ou expérimental, [44].

I.8. Nature du dépôt

I.8.1. Dépôt dur

Il s'agit d'une structure dense et renforcée qui ne s'atténue pas lors d'un simple jet d'eau ou de vapeur mais qui nécessite un traitement mécanique ou un nettoyage chimique approprié. C'est le cas de dépôt corrosif ou cristallin.

La résistance thermique d'un dépôt dur est directement proportionnelle à son épaisseur.

I.8.2. Dépôt poreux

C'est le matériau d'un dépôt dur qui se présente en une structure moins dense, sous l'effet des conditions opératoires. Ce cas est plus sérieux que le précédent quand le fluide emprisonné dans les pores a une conductivité thermique plus faible que le matériau solide.

I.8.3. Dépôt mou

C'est le cas de boues, poudres de coke ou de fibres végétales. La résistance dans ce cas est plutôt liée au fluide emprisonné qu'au matériau constituant la matrice. Un simple soufflage peut donner des résultats satisfaisants lors du nettoyage.

Dans la réalité, les industriels sont confrontés à une combinaison de plusieurs de ces mécanismes **figure I.13** conduisant à la formation d'un dépôt composite, [45,46]. Par

exemple, dans l'industrie laitière, lors de traitement de pasteurisation, le dépôt est majoritairement associé à la dénaturation thermique de protéines (la BLG) rendant son adhésion possible à la surface chaude, [47]. Dans ce cas le dépôt est composite, car des minéraux comme le calcium présent naturellement dans le lait participe aussi à la formation du dépôt.

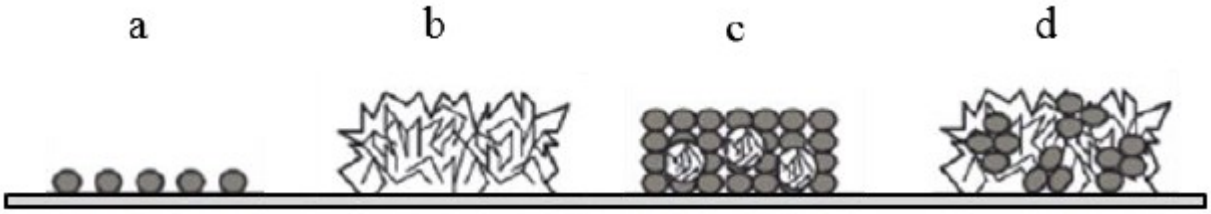


Figure I.13 : Exemples de dépôts formés suite à un traitement thermique des aliments : **a)** adsorption d'une monocouche de protéine, **b)** cristallisation, **c)** dépôt protéique avec inclusion de minéraux, **d)** dépôt minéral avec inclusions protéiques, [45].

I.9. Processus fondamentaux de l'encrassement

Phénoménologiquement, l'encrassement est un problème transitoire de chaleur et de masse qui nécessite l'action simultanée de plusieurs processus complexes. Epstein, [48].A décomposé les mécanismes d'encrassement selon 5 événements séquentiels :

I.9.1. L'initiation

L'initiation comme étant le temps nécessaire avant la formation du dépôt sur une surface propre. Il faut signaler que, dans la grande majorité des études expérimentales traitant de l'encrassement particulaire sur des tubes d'échangeurs, [49] la phase d'initiation du processus d'encrassement ne sont pas détectée.

Beaucoup de travaux de recherche donnent de plus en plus l'importance à cette phase initiale avant la formation du noyau cristallin encrassant. Actuellement, l'un des principaux objectifs des chercheurs est de donner un modèle capable de décrire la phase d'initiation de l'encrassement. Parmi leurs objectifs : augmentation du temps d'induction (le plus long possible). L'utilisation de nouveaux matériaux de surface, tel que le DLC (Diamond-LikeCarbon), permet de prolonger la phase d'induction, [50].

La surface rugueuse tend à diminuer le délai de la période. Elle fournit une situation favorable pour la cristallisation pendant que les rainures fournissent des régions pour le dépôt des particules.

I.9.2. Transport

Pendant cette phase, les substances d'encrassements du volume de fluide sont transportées à la surface de transfert. Le transport est gouverné par un nombre de phénomènes y compris la diffusion, la sédimentation et la thermophorèse. Une grande quantité d'information disponible pour chacun de ces phénomènes est appliquée pour étudier les mécanismes de transports pour les différentes catégories d'encrassement.

La thermophorèse est le mouvement de petites particules dans l'écoulement de fluide quand le gradient de température est présent. Les murs froids attirent les particules colloïdales pendant que les murs chauds repoussent ces particules. La thermophorèse est importante pour des particules autour de 5 µm de diamètre et devient dominante autour de 0.1 µm.

Un autre type de ces processus est électrophorèse (électrophorèses). L'impact inertiel et les tourbillons de turbulence peuvent être présentés. Le modèle théorique qui expose ce processus est disponible dans la littérature, [51].

I.9.3. Déposition

Une partie de la matière encrassant transportée est attachée à la surface. Les forces agissantes des particules proches de la surface sont importantes à déterminer l'attachement. En plus, les propriétés du matériel tel que la densité, la viscosité et les conditions de surface sont importantes. L'adhésion des particules sous l'effet des forces de Van der Waals, des forces électrostatiques ou capillaires.

Les forces de London-Van der Waals sont dues aux interactions entre les moments dipolaires générés par le mouvement des électrons autour des noyaux d'atomes neutres voisins. Dans des fluides de phase unique, les forces résultant entre particules et entre les particules et la paroi sont toujours attractives. Pour $dp \leq 100 \mu m$, les forces de Van Der Waals l'emportent sur les forces de gravité, [52].

I.9.4. Réentraînement (Enlèvement)

Le réentraînement des particules déposées dû aux forces de cisaillement s'exerçant sur le dépôt, à l'érosion ou à l'écaillage. Une certaine proportion de la matière est enlevée de la surface immédiatement après leur dépôt et un autre est enlevée plus tard. En général, les forces de cisaillement à l'interface entre le fluide et la couche de dépôt encrassant sont responsables de cet enlèvement. Les forces de cisaillement dépendent du gradient de la vitesse à la surface, de la viscosité du fluide et de la rugosité de la surface, [53-54].

I.9.5. Vieillissement

Le vieillissement du dépôt caractérisé par un changement de texture et une usure dudit dépôt. Une fois le dépôt est posé sur la surface, le vieillissement commence. Les propriétés mécaniques de ce dépôt seront modifiées durant cette phase, à cause du changement de cristal ou de la structure chimique, par exemple, l'empoisonnement lent du micro-organisme causé par la corrosion à la surface affaiblira et appauvrira la couche du bio-encrassement. La réaction chimique attire la surface du dépôt pour modifier la composition chimique du dépôt, et de cette façon changer les propriétés mécaniques, [55].

I.10. Conclusion

L'encrassement des échangeurs de chaleur a des conséquences économiques fâcheuses, nous pouvons noter :

- De nouveaux investissements de 10 à 50 %, [56] en raison d'un surdimensionnement et d'un remplacement précoce des échangeurs détériorés, [57] ont montré qu'un surdimensionnement des échangeurs de chaleur de 30 à 40 % entraîne des coûts supplémentaires d'environ 25 %. Une mauvaise évaluation de l'encrassement peut également engendrer un sous-investissement entraînant un mauvais fonctionnement de l'installation ;
- Le coût du nettoyage des équipements dû à l'utilisation excessive d'eau de rinçage et de détergents (acide, soude). L'encrassement des installations et leur nettoyage représente 80 % des coûts de production dans les industries laitières, [58]. Environ 3 kg d'agents désinfectants et nettoyants et 1,5 m^3 d'eau, [59] sont nécessaires par tonne de lait traité, correspondant en Allemagne à une consommation annuelle de 70–90 millions de tonnes d'agents nettoyants et désinfectants et 45 millions de m^3 d'eau, [45].

Pour d'autres produits laitiers tels que le fromage ou le yaourt, la consommation de l'eau peut aller jusqu'à 6 m^3 par tonne de produit, [59] :

- Le coût des opérations supplémentaires de maintenance. Environ 15 % de ces coûts sont attribués à l'entretien des échangeurs de chaleur et des chaudières et 50 % sont dus à l'encrassement, [60] ;
- Les dépenses énergétiques supplémentaires générées par la diminution du coefficient de transfert thermique et par l'augmentation de la puissance mécanique nécessaire au pompage du fluide ;

- Le coût de l'immobilisation des installations pour procéder à des opérations de nettoyage impactant fortement la marche globale du site, [45] a estimé cette perte a environ 1,5 millions $/jour.

Dans ce contexte, la minimisation de l'encrassement représente un enjeu important autant d'un point de vue scientifique (compréhension des mécanismes d'encrassement) qu'industriel (réduction des coûts de production et amélioration de la qualité des produits).

Chapitre II
Etat de l'art sur la modélisation de l'encrassement des échangeurs de chaleur

II.1. Introduction

Les échangeurs de chaleur sont largement utilisés dans les applications d'ingénierie telles que les systèmes de réfrigération et de climatisation, les automobiles, les centrales thermiques, les industries de traitement chimique et textile, etc. Les échangeurs de chaleur sont les dispositifs facilitant un transfert de chaleur efficace entre les deux fluides en raison de leurs différences de température. La complexité de l'analyse des échangeurs de chaleur doit être due à sa géométrie et aux phénomènes physiques impliqués lors de l'échange de chaleur entre les fluides. En général, les échangeurs de chaleur sont étudiés à la fois analytiquement et expérimentalement en utilisant la première et deuxième loi de la thermodynamique, [61]. L'analyse théorique de l'échangeur de chaleur implique plus d'hypothèses et d'équations compliquées, tandis que les méthodes expérimentales sont plus chères en raison de son investissement initial requis pour développer une configuration expérimentale, [62]. Pour surmonter ces difficultés, des modèles RNA ont été développés pour la simulation, l'optimisation et la prédiction des performances des systèmes thermiques impliquant des échangeurs de chaleur, [63, 64]. RNA établit les corrélations sur la base de certaines données d'apprentissage, ce qui ne nécessite aucune équation analytique spécifique ni description de système. Les paramètres non linéaires impliqués dans les processus de transfert de chaleur des échangeurs de chaleur peuvent être corrélés en utilisant RNA avec des erreurs minimales.

Des travaux vastes ont été effectués par les chercheurs en vue de trouver un modèle approprié pour estimer ou prédire l'encrassement des échangeurs de chaleur. Et ça ce qu'on veut montrer dans ce chapitre, où nous revenons à la littérature afin de voir les différentes techniques utilisées en terme de "modélisation de l'encrassement des échangeurs de chaleur" et en montrant aussi qu'il est possible d'aborder ce sujet à plusieurs angles.

II.2. Production scientifique mondiale sur la modélisation de l'encrassement des échangeurs de chaleur

Avant d'aller plus en détail sur les différentes techniques utilisées pour la modélisation de l'encrassement des échangeurs de chaleur, nous avons décidé de faire une étude bibliographique concernant les publications scientifiques centrées sur ce domaine.

La **Figure II.1** résume l'évolution de nombre des articles publiés dans ce domaine en fonction des périodes en utilisant 'Science direct ' et 'Google scholar' comme des références, on note un développement remarquable dans les dernières années. La méthodologie est basée sur la recherche des mots-clés proposés dans les publications antérieures.

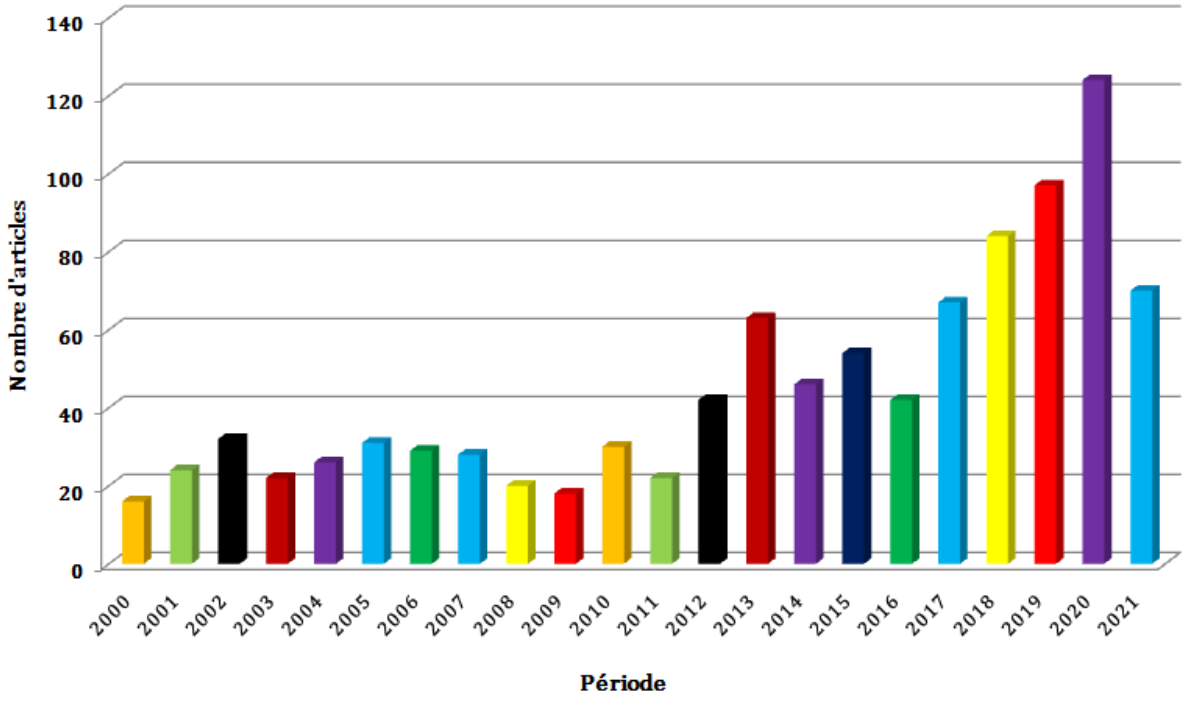


Figure II.1 : Evolution du nombre d'articles publiés sur la modélisation de l'encrassement des échangeurs de chaleur "Science direct et Google scholar"

II.3. Approches de modélisation

Une analyse de modèles d'encrassement disponibles dans la littérature est proposée dans ce paragraphe. Ils sont divisés selon trois catégories allant des descriptions phénoménologiques aux modèles les plus complets.

Les configurations géométriques considérées dans les différentes études sont variées. Elles peuvent toutefois être assimilées à un domaine fluide noté $\boldsymbol{l}$ et un domaine solide noté $\boldsymbol{s}$ correspondant au dépôt, séparés par une interface. Cette dernière, notée $\boldsymbol{\Sigma}$, est mobile et se déplace selon que le dépôt croît ou décroît. La hauteur du dépôt solide est notée $\boldsymbol{h}$. La **Figure II.2** illustre la configuration retenue.

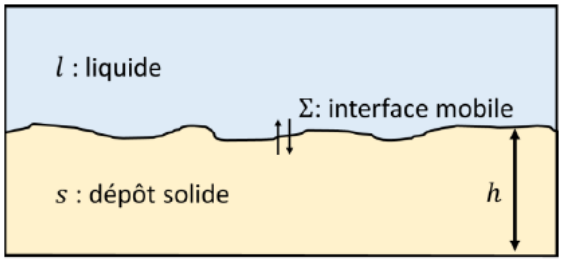


Figure II.2 : Représentation schématique de la configuration considérée, [65].

II.3.1. Modèle de croissance

La première approche de modélisation de l'encrassement se trouve être aussi la plus ancienne. Elle correspond à une volonté de prédire les effets de l'encrassement en calculant l'épaisseur du dépôt afin d'en déterminer sa résistance d'encrassement R_f. Celle-ci, aussi appelée facteur d'encrassement, est définie par, [66] :

$$R_f = \frac{h}{\lambda_s} \tag{II.1}$$

Avec λ_s la conductivité thermique du solide. On note R_f la résistance d'encrassement lorsque le dépôt est à l'équilibre, c'est-à-dire lorsque l'on a atteint l'épaisseur maximale de solide. Il s'agit de l'asymptote à la courbe d'évolution de R_f. Dans certains cas, lorsqu'il n'y a pas de réentraînement de solide dans le liquide, la croissance du solide n'atteint pas de maximum. Les valeurs de résistance à l'équilibre sont répertoriées dans la classification TEMA. Elles sont utilisées afin de prendre en compte la résistance thermique du dépôt lors du dimensionnement des échangeurs de chaleur.

Afin de prédire les valeurs de résistance d'encrassement, il faut être capable de calculer l'épaisseur du dépôt. Ainsi, en 1959, Kern et Seaton ont proposé de modéliser l'évolution de cette épaisseur par un bilan matière très simple sur la couche de solide formée, [67] :

$$\rho_s \frac{dh}{dt} = F_{m_d} - F_{m_r} \tag{II.2}$$

Où ρ_s est masse volumique du dépôt solide. Les termes F_{md} et F_{mr} désignent respectivement le taux de déposition de solide et le taux de réentraînement, par unité de surface. Ce principe de décomposition est valable en particulier pour les dépôts formés par cristallisation et sédimentation. Krause distingue trois mécanismes de réentraînement différents, [68]. Ces mécanismes de déposition et réentraînement sont illustrés sur la **Figure II.3**. Lorsque le dépôt croit, l'espace disponible pour le fluide diminue, sa vitesse augmente alors. Ainsi, des parties du dépôt peuvent être arrachées aléatoirement par l'écoulement fluide. Un phénomène d'érosion plus régulier de

particules plus fines peut aussi avoir lieu à la surface du dépôt. Le troisième type de réentraînement possible correspond à la dissolution d'une partie du dépôt formé.

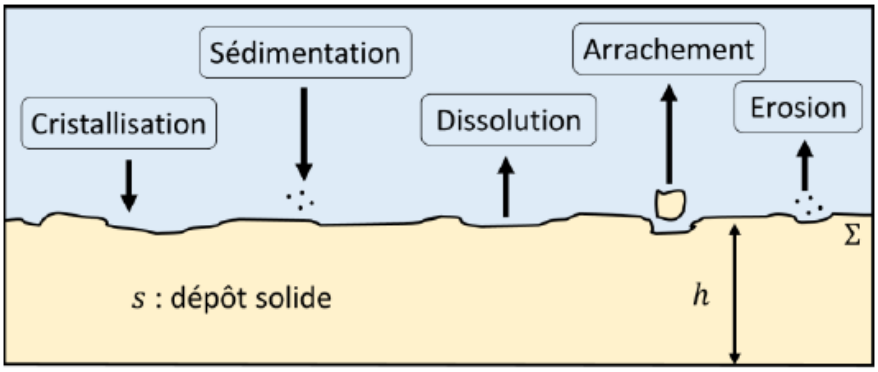


Figure II.3 : Mécanismes de déposition et de réentraînement, [65].

Kern et Seaton proposent une expression de ces termes de déposition et réentraînement, mais uniquement dans le cas de l'encrassement par sédimentation, [67]. En effet, comme nous l'avons vu dans la partie précédente, les échangeurs pour eaux géothermales sont plutôt confrontés à des problèmes d'encrassement par cristallisation de sels dissouts dans une phase aqueuse. On se concentre ainsi sur les réactions hétérogènes à l'interface liquide-dépôt, dont la cristallisation fait partie. Le terme de réentraînement que ces auteurs proposent reste valable puisqu'il est généralement considéré comme indépendant de la façon dont le dépôt se forme [68]. Ils décrivent l'arrachement comme une fonction de la contrainte tangentielle τ_s exercée par le liquide sur le solide, [67] :

$$F_{m_r} = B_1 \tau_S h \qquad \text{(II.3)}$$

Dans cette équation, B_1 est une constante arbitraire. La contrainte tangentielle est une fonction de la vitesse de l'écoulement fluide. En 1987, Bohnet propose une autre description du terme d'arrachement, basée sur un bilan des forces s'exerçant sur le dépôt solide

$$F_{m_r} = B_2 \frac{\tau_s}{\sigma_s} \left(\frac{\mu_l\, g}{\rho_l}\right)^{1/3} \qquad \text{(II.4)}$$

Où σ_s correspond à la résistance du dépôt au cisaillement et B_2 une constante [61]. La lettre g désigne l'accélération de la pesanteur, μ_l la viscosité dynamique du liquide et ρ_l la masse volumique liquide.

Il existe d'autres modélisations du terme de réentraînement, [69-72] mais c'est celle de Bohnet qui est généralement utilisée en pratique.

Les phénomènes de dépôt et de réentraînement dans le cas d'un liquide peuvent être représentés selon le schéma de la **Figure II.4**.

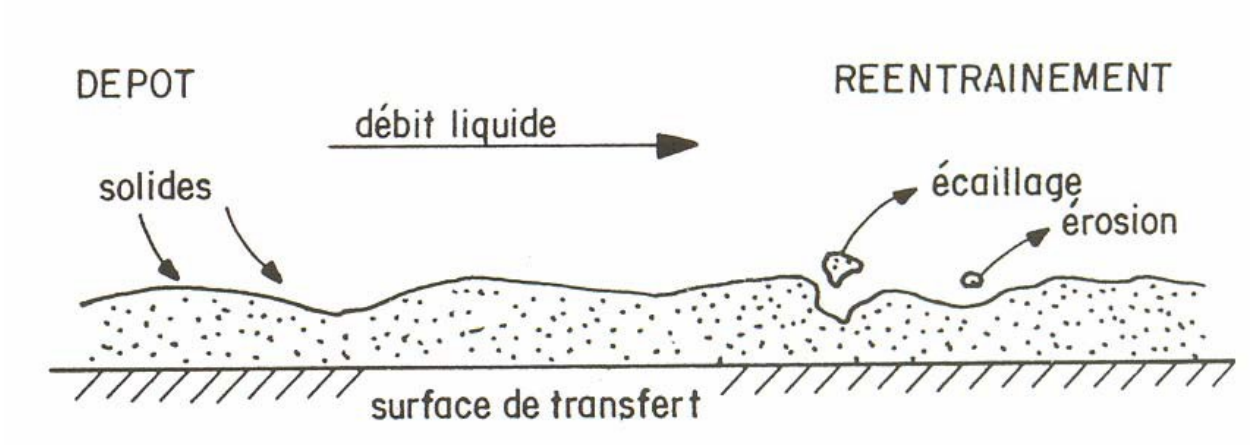


Figure II.4 : Représentation schématique de l'encrassement dans le cas d'un liquide, [73].

Dès 1924, McCabe et Robinson ont proposé une modélisation du taux de déposition dans un cas d'encrassement par cristallisation, par une simple relation de proportionnalité avec le flux de chaleur imposé, [74]. Deux ans après la publication de référence de Kern et Seaton, [62,70]. Améliorent cette description et modélisent le taux de déposition comme une fonction de la concentration massique dans la phase liquide de l'espèce apparente $\boldsymbol{i}$ qui dépose, $\boldsymbol{\rho_{li}}$ et du flux de chaleur $\boldsymbol{q}$ imposé par unité de surface, [75]:

$$\boldsymbol{F_{m_d} = B_3 \rho_{li} (q)^2} \qquad \text{(II.5)}$$

Ici, $\boldsymbol{B_3}$ est une constante. De nombreuses autres modélisations des termes de déposition ont été proposées par la suite, [76-81]. Krause présente une revue critique de ces différents modèles, [68].

En 1987, Bohnet propose une nouvelle modélisation de l'encrassement par cristallisation, basée sur la théorie du film, [66]. Le principe est fondé sur la continuité des flux de matière à l'interface : le flux diffusif de l'espèce apparente qui dépose est exactement égal au flux qui cristallise à l'interface. Le taux de déposition s'exprime alors, en prenant en compte la diffusion de l'espèce et, en fonction de la réaction de cristallisation.

$$\boldsymbol{F_{m_d} = k_{diff} \left(\rho_{li} - \rho_{li}^{\Sigma} \right)} \qquad \text{(II.6)}$$

$$\boldsymbol{F_{m_d} = k_{react} \left(\rho_{li}^{\Sigma} - \rho_{li}^{sat} \right)^n} \qquad \text{(II.7)}$$

Où k_{diff} et k_{react} désignent respectivement les constantes de diffusion et de réaction. Le terme ρ_{li}^{Σ} désigne la concentration massique de l'espèce i à l'interface Σ et ρ_{li}^{sat} la concentration à saturation. La **Figure II.5** illustre les profils de concentration, ainsi que la couche limite dans laquelle s'effectue la diffusion. La concentration dans le reste de la phase ρ_{li} est supposée constante. L'exposant n désigne l'ordre de la réaction de cristallisation.

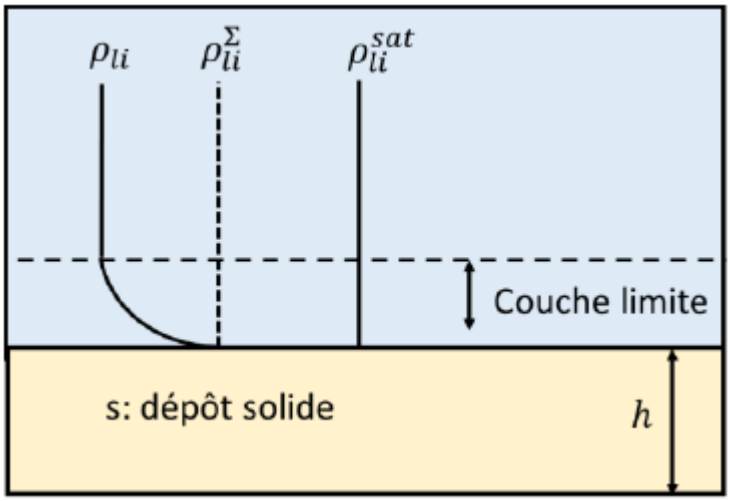


Figure II.5 : Profils de concentration au voisinage du dépôt solide, [65].

La concentration sur l'interface entre le liquide et le dépôt est difficile à mesurer expérimentalement et est donc une inconnue. En combinant les deux expressions précédentes, il est possible d'éliminer ce terme. Nous obtenons alors une expression générale qui dépend de n :

$$\rho_{li} - \rho_{li}^{sat} = \frac{F_{m_d}}{k_{diss}} + \left(\frac{F_{m_d}}{k_{react}}\right)^{1/n} \quad \text{(II.8)}$$

Dans la majorité des cas, les réactions considérées sont d'ordre 1 ou 2. Le taux de déposition peut alors être exprimé dans ces deux cas :

- Si $n=1$:

$$F_{m_d} = \frac{1}{\frac{1}{k_{react}} + \frac{1}{k_{diss}}}(\rho_{li} - \rho_{li}^{sat}) \quad \text{(II.9)}$$

- Si $n=2$:

$$F_{m_d} = k_{diss}\left(\frac{1}{2}\frac{k_{diss}}{k_{react}} + (\rho_{li} - \rho_{li}^{sat}) - \sqrt{\frac{1}{4}\left(\frac{k_{diss}}{k_{react}}\right)^2 + \frac{k_{diss}}{k_{react}}(\rho_{li} - \rho_{li}^{sat})}\right) \quad \text{(II.10)}$$

Ces différentes descriptions du phénomène d'encrassement sont basées uniquement sur des valeurs moyennes de concentration, vitesse ou température. Cela suppose donc un encrassement uniforme. Le caractère mobile de l'interface séparant le liquide et le dépôt solide peut être pris en compte via la résolution de **l'éq. (II.5)** permettant d'obtenir l'évolution de la hauteur moyenne de dépôt en fonction du temps. Les travaux récents de Xu et al. Illustrent l'utilisation de ce type de modèle, où le taux d'encrassement d'un échangeur par cristallisation de sulfate de calcium est calculé à différentes concentrations et températures, [82].

II.3.2. Approche avec découplage entre le transport interne et le flux de solide à l'interface

Avec le développement de la CFD (Computational Fluid Dynamics) au début des années 2000, la simulation de l'écoulement d'un fluide, couplé à la résolution numérique du transport de chaleur et de matière est devenue possible. Cette approche permet d'améliorer le calcul des taux de déposition et réentraînement, en prenant en compte les champs des différentes variables et ainsi prédire les variations spatiales de l'encrassement. Toutefois, dans l'approche décrite ici, le calcul des champs dans le fluide est découplé du calcul des flux à l'interface.

On distingue ici deux niveaux de description. Dans le premier, la concentration de l'espèce qui dépose est supposée uniforme, le transport des espèces dans le fluide est estimé à l'aide du coefficient de transport k_{diss}. Dans la seconde, le transport des espèces est résolu, ce qui permet d'avoir accès directement aux concentrations sur l'interface entre le liquide et le dépôt.

II.3.2.1. Concentration constante dans le fluide

Une des premières utilisations de la CFD pour la simulation du phénomène d'encrassement peut être attribuée à une équipe de l'université de Braunschweig, [83, 84]. Afin de décrire l'encrassement d'un échangeur de chaleur à plaques par cristallisation de sulfate de calcium, ils utilisent une approche découplée, en supposant un champ de concentration uniforme dans le fluide. Le modèle à l'interface permettant d'estimer le flux d'encrassement est celui de Bohnet, décrit dans la partie précédente, [61]. Le terme de déposition de ce modèle fait intervenir un coefficient de transport k_{diss} et de réaction k_r qui sont respectivement des fonctions de la vitesse du liquide et de la température. Le taux de réentraînement dépend aussi de la vitesse de l'écoulement. Ainsi, la résolution quasi-stationnaire de l'écoulement non isotherme du fluide permet

de calculer à un instant **t** et en une position donnée le long du tube, le flux de solide formé. On peut ainsi en déduire une hauteur de dépôt formée sur un intervalle de temps donné. Cette épaisseur de dépôt impacte l'écoulement du fluide. Le caractère isolant du dépôt affecte aussi le champ de température. Les champs de vitesse et température doivent alors être recalculés. Le nouveau flux d'encrassement est ensuite calculé, de façon itérative.

Pour le calcul du nouveau champ de vitesse, Brahim et al. Ont introduit le principe de la "croissance fictive ", illustré sur la **Figure II.6** et comparé à la croissance réelle du dépôt, [85]. Les exposants ***in***, ***f*** et **0** font référence respectivement à la valeur de la vitesse en entrée, au niveau du dépôt et initiale. En réalité, lorsque le dépôt croit, la vitesse du fluide au-dessus de celui-ci croit proportionnellement à sa hauteur. La géométrie doit donc être modifiée en permanence. Afin de contourner ce problème les auteurs proposent d'impacter la vitesse d'entrée du fluide en fonction de la hauteur du dépôt à l'instant **t**. Ceci implique de calculer une valeur moyenne de ***h***, étant donné que le dépôt n'est en réalité pas uniforme sur la longueur de la plaque.

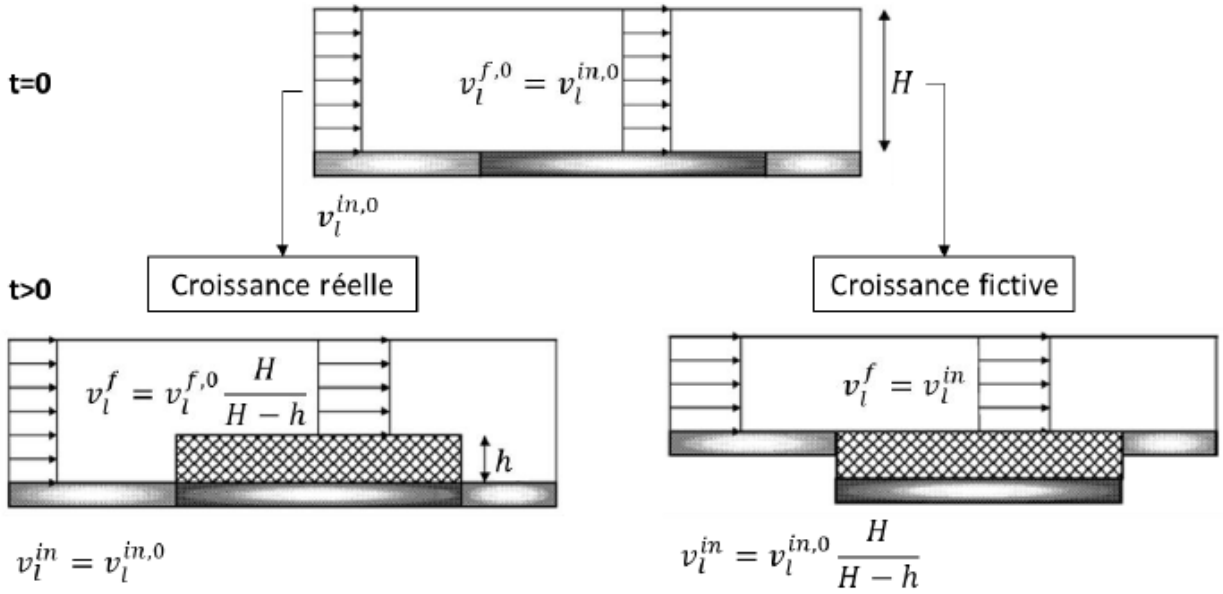


Figure II.6 : Principe de la croissance fictive, [85].

Afin de prendre aussi en compte l'impact de l'augmentation de l'épaisseur du dépôt sur le champ de température, la résolution de l'équation de conservation de l'énergie au sein du solide devrait être mis en œuvre et couplée à celle du liquide. Les auteurs s'affranchissent de cette difficulté en imposant simplement un flux de chaleur ***q***

imposé à la paroi, géré par une distribution adaptée en fonction de l'épaisseur de solide le long du tube.

Une étude similaire de cristallisation du sulfate de calcium a été publiée par Mwaba, M. et al. [86]. Le champ de température dans le fluide est résolu à l'aide d'un logiciel de type CFD. La vitesse de l'écoulement est supposée constante. Le nouveau champ de température est simplement recalculé en fonction de l'épaisseur du dépôt en tout point le long du tube, déduite des résultats à l'instant précédent. Le réentrainement est négligé. Comme attendu, les auteurs concluent que la température de surface du dépôt diminue lorsque son épaisseur augmente, ce qui ralenti donc la vitesse de cristallisation.

Afin d'améliorer ces descriptions, basées sur des approximations du transport des espèces, il est nécessaire de résoudre toutes les équations de conservation dans la phase fluide. La partie suivante présente cette approche.

II.3.2.2. Résolution du transport de matière dans le fluide

Dans les publications où le transport des espèces est modélisé, les équations de conservation de la masse et de la quantité de mouvement pour chaque espèce sont généralement résumées par l'équation suivante, pour chaque espèce $\boldsymbol{i}$

$$\frac{\partial \boldsymbol{\rho_{li}}}{\partial \boldsymbol{t}} + \boldsymbol{\nabla}.(\boldsymbol{j_{li}} + \boldsymbol{\rho_{li}} \boldsymbol{v_l}) = \boldsymbol{r_i} \qquad \text{(II.11)}$$

Où $\boldsymbol{\rho_{li}}$ désigne la concentration massique de l'espèce $\boldsymbol{i}$ dans le fluide et $\boldsymbol{r_i}$ le taux d'accroissement massique de $\boldsymbol{i}$ par unité de volume, par réaction chimique homogène. Le terme $\boldsymbol{j_{li}}$ représente le flux diffusif massique, le plus souvent modélisé simplement par la loi de Fick

$$\boldsymbol{j_{li}} = -\boldsymbol{D_i} \boldsymbol{\nabla \rho_{li}}$$

Où $\boldsymbol{D_i}$ est le coefficient de diffusion de l'espèce $\boldsymbol{i}$. La résolution de **l'éq. (II.11)** permet de s'affranchir de l'utilisation de **l'éq. (II.6)** car on a ainsi directement accès à la concentration sur l'interface $\boldsymbol{\rho_{li}^{\Sigma}}$. La condition à la limite s'exprime alors en fonction de la cinétique de réaction (II.7).

$$(\boldsymbol{j_{li}} + \boldsymbol{\rho_{li}} \boldsymbol{v_l}) \boldsymbol{n_l} = \boldsymbol{k_{react}} \left(\boldsymbol{\rho_{li}^{\Sigma}} - \boldsymbol{\rho_{li}^{sat}}\right)^{\boldsymbol{n}} \qquad \text{(II.12)}$$

Les travaux basés sur cette approche, publiés en 2015 par Zhang et al. et Xiao et al. [87,88] visent directement à améliorer la description de croissance fictive de Brahim et al. [84]. Une approche " pseudo dynamique " est présentée, dans laquelle les phénomènes sont décrits comme une succession d'états stationnaires. La résolution des

équations internes est toujours découplée du calcul des flux de matière solide à l'interface liquide-dépôt, mais la géométrie est reconstruite à intervalle régulier afin de prendre en compte la croissance solide. A chaque itération, les champs de température sont calculés dans le fluide et le solide, ce qui, couplé à la résolution de l'équation de conservation des espèces dans la phase liquide, permet d'estimer le flux de matière qui dépose à l'interface. En fonction de cela, la nouvelle épaisseur du dépôt en chaque point le long du tube est déterminée afin de modifier les dimensions du domaine solide. Ainsi la modification de la vitesse d'entrée du fluide n'est plus nécessaire, l'impact de la réduction du diamètre sur le champ de vitesse au-dessus du dépôt est directement pris en compte.

Le modèle complet est ensuite appliqué à la cristallisation de sulfate de calcium. Les résultats de simulations sont comparés aux données expérimentales obtenues par Brahim et al. [84]. Dans les deux cas, on note une assez bonne concordance entre la résistance d'encrassement déterminée par la simulation et celle mesurée expérimentalement. Dans les conditions opératoires testées, les auteurs utilisant l'approche avec résolution du transport dans le fluide obtiennent une meilleure adéquation. Dans tous les cas, les prédictions sous-estiment les résistances d'encrassement.

D'autres études sont basées elles aussi sur une approche découplée, avec résolution du transport des espèces dans le fluide. Pääkkönen et al. S'intéresse à la précipitation de carbonate de calcium sur une plaque plane représentant un échangeur de chaleur idéalisé, [89]. De nombreuses simplifications sont effectuées pour le modèle : l'impact du dépôt solide sur l'écoulement fluide est négligé. L'arrachement l'est également et le taux de déposition est supposé constant. Les analyses des résultats présentées sont plutôt d'ordre phénoménologique. Les auteurs concluent que le paramètre prépondérant affectant le phénomène d'encrassement est la température de surface du dépôt. Le second paramètre identifié, bien qu'avec un effet moindre, est la contrainte de cisaillement, agissant sur le taux de réentraînement. Une comparaison entre la prédiction de la résistance d'encrassement et les valeurs expérimentales est également présentée, mais l'adéquation entre les deux est extrêmement variable suivant les conditions opératoires. La **Figure II.7** illustre deux cas extrêmes, avec simplement une variation de la concentration en calcium.

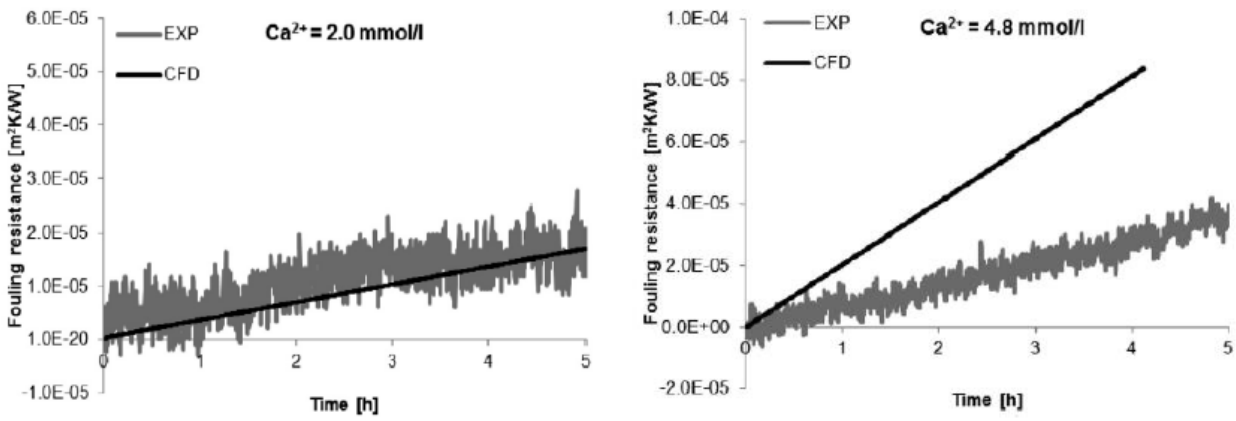


Figure II.7 : Comparaison entre la résistance d'encrassement mesurée expérimentalement et prédite par les simulations, à deux concentrations en calcium, [89].

Dans les études de Kieffer et al. Jin et al. et de Haghshenasfard et al. Utilisant la même approche, les effets du dépôt sur les champs des variables dans le fluide sont également négligés, [90-92].

Dans toutes ces publications, le flux de déposition est introduit via le terme r_i de **l'éq. (II.11).** Ceci revient à considérer que l'encrassement se produit par une réaction homogène. En revanche, les auteurs traitent ensuite le dépôt comme s'il était produit à la paroi. Considérer une cristallisation homogène est possible, mais elle implique de mettre en place des modèles de nucléation puis de sédimentation afin de décrire la migration des particules solides formées au sein du fluide jusqu'à la paroi, ce qui n'est pas fait. Par ailleurs, les phénomènes de cristallisation et de sédimentation sont généralement distingués dans la théorie de l'encrassement, [41]. Le terme de réaction homogène r_i devrait donc être nul, le taux d'encrassement intervenant uniquement dans les conditions aux limites sur l'interface liquide-dépôt.

Une description plus précise du phénomène d'encrassement passe par une meilleure modélisation des conditions aux limites sur l'interface entre la phase fluide et le dépôt solide. Elles permettent d'envisager une troisième approche avec un couplage complet entre les équations de conservation dans les phases et les flux à l'interface.

II.3.3. Approche avec couplage du transport interne et des flux à l'interface

La troisième approche de la modélisation de l'encrassement consiste à écrire les équations de conservation dans les phases liquide et solide, séparés par une interface mobile dont la vitesse est notée w. Les flux des espèces à l'interface sont alors

entièrement couplés avec les champs des variables de concentration, vitesse et température dans le domaine fluide, via l'écriture des conditions à la limite. Ici encore, l'interface est le siège d'une réaction hétérogène.

L'éq. (II.11) traduit la conservation des espèces dans la phase liquide, mais dans ce cas le terme source par réaction chimique homogène est nul. On a alors pour chaque espèce *i* :

$$\frac{\partial \rho_{li}}{\partial t} + \nabla.(\boldsymbol{j}_{li} + \rho_{li}\boldsymbol{v}_l) = \mathbf{0} \qquad \text{(II.13)}$$

L'expression des flux des espèces liquide et solide à l'interface permet de faire le lien entre le transport interne et la vitesse de l'interface. Le flux liquide s'écrit, pour chaque espèce $\boldsymbol{i}$

$$\rho_{li}(\boldsymbol{v}_{li} - \boldsymbol{w}).\boldsymbol{n}_l = -r_{li}^{\Sigma} \qquad \text{(II.14)}$$

tandis que le flux de solide, permettant de calculer la vitesse de l'interface $\boldsymbol{w}$ s'exprime :

$$\rho_s(\boldsymbol{v}_s - \boldsymbol{w}).\boldsymbol{n}_l = r_s^{\Sigma} \qquad \text{(II.15)}$$

Dans la phase solide il est généralement supposé que $\boldsymbol{v_s}$=**0** et que la masse volumique ρ_s est constante, ce qui permet aux auteurs de s'affranchir de l'écriture des équations de conservation de la masse et de la quantité de mouvement dans cette phase. Dans ces équations ((II.14) et (II.15)), r_{li}^{Σ} et r_s^{Σ} désignent respectivement le taux de production/disparition massique de l'espèce $\boldsymbol{i}$ dans la phase liquide et du solide par réaction chimique hétérogène. Ces deux grandeurs sont reliées par une relation linéaire découlant de l'équation de la réaction. Notons qu'en se ramenant à la notation précédente, le taux de réaction de la phase solide à l'interface peut s'écrire :

$$r_s^{\Sigma} = F_{m_d} - F_{m_r} \qquad \text{(II.16)}$$

Pour exprimer le taux de réaction, il est possible soit d'utiliser une loi cinétique comme nous l'avons vu précédemment, soit de supposer que l'équilibre est instantanément atteint sur l'interface.

II.4. Approche d'intelligences artificielles

Les réseaux de neurones artificiels (RNA) ont été largement utilisés pour l'analyse thermique d'échangeurs de chaleur au cours des deux dernières décennies. Les études rapportées sur l'analyse thermique des échangeurs de chaleur sont classées en quatre groupes principaux, à savoir :

- La modélisation des échangeurs de chaleur.

- L'estimation des paramètres de l'échangeur de chaleur.
- L'estimation des caractéristiques de changement de phase dans les échangeurs de chaleur.
- La régulation des échangeurs de chaleur.

La plupart des articles relatifs aux applications de l'RNA pour l'analyse thermique d'échangeurs de chaleur sont discutés. Les limites de l'RNA pour l'analyse thermique des échangeurs de chaleur et ses besoins en matière de recherche dans ce domaine sont soulignées. RNA gagne en popularité en tant qu'outil pouvant être utilisé avec succès pour l'analyse thermique d'échangeurs de chaleur avec une précision acceptable.

Certaines des études sur les échangeurs de chaleur examinées précédemment font état de la conception et du développement d'échangeurs de chaleur à plaques, [93], d'échangeurs de chaleur à base de céramique, [94], applications des échangeurs de chaleur compacts, [95], encrassement des échangeurs de chaleur dans les systèmes de climatisation d'aéronefs, [96], l'application de nano-fluides dans les échangeurs de chaleur, [97] et la dynamique des fluides numérique dans la conception des échangeurs de chaleur, [98]. De même, de nombreux chercheurs ont examiné les applications du RNA dans les systèmes de réfrigération, de climatisation et de pompes à chaleur, [98], les problèmes de transfert de chaleur en génie nucléaire, [99], le dimensionnement des systèmes solaires photovoltaïques, [100], la modélisation et le contrôle des processus de combustion, [101], modélisation des systèmes énergétiques, [102], modélisation des systèmes à énergies renouvelables, [103] et pour le contrôle de procédés chimiques, [104]. Les études précédentes sur les échangeurs de chaleur et les applications techniques de la société RNA ont confirmé qu'aucune étude spécifique n'a été rapportée sur l'utilisation de la technologie RNA pour les applications d'échangeurs de chaleur.

II.4.1. Modélisation d'échangeurs de chaleur à l'aide de réseaux de neurones artificiels

Les architectures RNA couramment utilisées pour l'analyse thermique des échangeurs de chaleur sont les réseaux à couche réactive multicouches, les réseaux à fonction polarisée radiale, les réseaux de neurones à régression généralisée et les systèmes à interface adaptative neuro-floue. Les informations de base sur les architectures RNA elles sont très disponibles et détaillées dans la littérature, [100-104].

Bien que les RNA font partie des modèles de boites noires qui représentent une relation empirique entre des ensembles d'entrées et de sorties, le choix de variables

d'entrées et de sorties est décisif pour que le modèle neuronal se rapproche des modèles déterministes. Par conséquent la sélection des données expérimentales de la résistance à l'encrassent des échangeurs de chaleur, le choix des variables d'entrées et de sorties et le prétraitement des données constituent la première étape de la modélisation neuronale de l'encrassent des échangeurs de chaleur.

L'étape suivante concerne le choix des paramètres du réseau de neurones qui vont permettre au réseau d'apprendre à partir des données sélectionnées la relation entre les entrées et les sorties choisies.

La troisième étape est consacrée à l'opération d'apprentissage et le test de généralisation du réseau choisi. Enfin la performance du réseau peut être, éventuellement, comparée avec celles des autres types de modélisation.

La **figure II.8** résume les étapes de la méthodologie utilisée dans ce travail pour la modélisation neuronale de l'encrassement des échangeurs de chaleur.

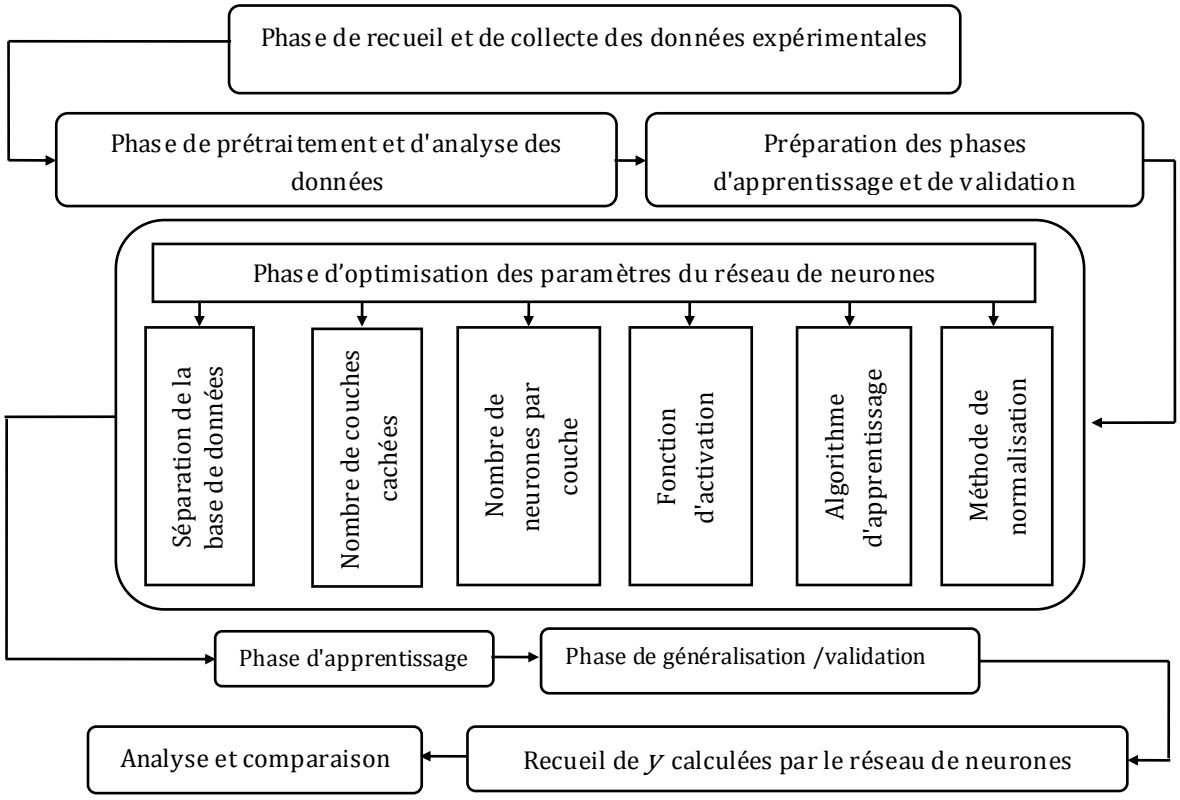


Figure II.8 : Etapes de la procédure de modélisation neuronale, [105].

II.4.2. Méthode des machines à vecteurs de support (SVM)

En anglais Support Vector Machine (SVM), les machines à vecteurs de support est une approche intelligente a été introduite pour la première fois par Vapnik (1998), [102] sont basées sur la théorie de l'apprentissage statistique (SLT) et sur le principe de minimisation du risque structurel (SRM). Les SVM obtiennent la solution en résolvant la programmation quadratique (QP), tout en évitant les minima locaux et constituent un avantage par rapport aux autres techniques de régression, [107].

II.4.3. Applications de l' RNA pour l'analyse des échangeurs de chaleur

Les études rapportées pour l'analyse thermique des échangeurs de chaleur sont classées en quatre sous-sections **Tableau II.1** basées sur les applications de l' RNA comme :

- Modélisation des échangeurs de chaleur, [108 - 176].
- Estimation des paramètres des échangeurs de chaleur, [177 - 203].
- Estimation des caractéristiques de changement de phase dans les échangeurs de chaleur, [204 - 243].
- Le contrôle des échangeurs de chaleur, [244 - 256].

II.5. Estimation des paramètres des échangeurs de chaleur

Le coefficient de transfert de chaleur (h), le facteur d'encrassement (R_{fo}) et le facteur de friction (f) sont les trois paramètres importants relatifs à tout échangeur de chaleur en fonctionnement. De nombreux chercheurs utilisant RNA ont cherché à estimer ces paramètres d'échangeurs de chaleur avec une meilleure précision.

II.5.1. Estimation du coefficient de transfert de chaleur (h)

Jambunathan et al. [177] ont évalué la convection ***h*** à l'aide d'un **MLFFN** en référence à la distribution de température non dimensionnelle, **α** et temps. Il a été rapporté que **MLFFN** avec une configuration 3-6-3-1 prédit le h convectif avec des écarts d'environ $\pm$ 2,7%. Dans le pire des cas, une erreur moyenne de $\pm$ 6,5% a été obtenue à partir d'une configuration 3-4-3-1, ce qui confirme que le réseau a convergé plus rapidement avec un nombre croissant de nœuds dans la première couche cachée. Dans un autre ouvrage de Ghajar et al. [178], une corrélation améliorée a été développée pour prédire le ***h*** d'un tube d'échangeur de chaleur horizontal (avec trois configurations d'entrée telles que des entrées réentrantes, à bords carrés et à embouchure en condition de limite de flux thermique de paroi

uniforme) en utilisant **MLFFN**. Dans leur travail, les valeurs h ont été prédites en référence à Re, Pr, Gr, X / d et μ_{bl} / μ_{wa}. Un total de 1290 points de données (441 pour les réentrants, 416 pour les bords carrés et 433 pour les cloches) ont été utilisés comme données d'apprentissage pour le réseau. Il a été signalé que la configuration 5-11-1 **MLFFN** prédit les valeurs h dans un écart de 5%.

Islamoglu et Kurt, [179] ont estimé le Nu en utilisant un modèle **MLFFN**. L'analyse de transfert de chaleur a été effectuée dans un échangeur de chaleur à canaux ondulés. Quatre entrées du réseau représentant, angle d'ondulation, longueur axiale du cycle, d_h et Re. La sortie du réseau était Nu. Le réseau avec une configuration 4-5-1 prédit le Nu avec des erreurs relatives maximales et minimales de 10% et 0,25% et des **MRE** inférieurs à 3,36%. De même, un modèle physique-empirique basé sur **MLFFN** a été développé pour prédire le $\dot{Q}$ dans une bobine hélicoïdale utilisant une solution d'huile et de glycérol / eau comme fluide de travail, [180]. Un modèle **MLFFN** avec quatre neurones dans la couche d'entrée représentant Pr, Ra, le diamètre hélicoïdal et le nombre de tours de bobines a été développé pour prédire le Nu de la solution d'huile et de glycérol / eau. Le réseau avec une configuration 4-4-1 prédit le Nu avec une valeur R de 0,98 par rapport aux résultats expérimentaux.

Mehrabi et al. [181] ont utilisé l'**ANFIS** pour prédire les caractéristiques U et Δp des échangeurs de chaleur hélicoïdaux à double tube en se référant à cinq variables d'entrée telles que le nombre de doyens intérieur et annulaire, le Pr intérieur et annulaire et le pas de la bobine. Leurs résultats ont montré que l'**ANFIS** prédit le U, le Δp interne et le Δp annulaire avec des valeurs R de 0,994, 0,995 et 0,951, respectivement, et les erreurs RMS correspondantes de 13,61%, 5,08% et 13,81%. De même, Kamble et al. [182] ont prédit le h et le Nu en utilisant **MLFFN** en référence à la taille des particules, au ΔT entre le lit et la surface immergée et à la vitesse de fluidisation. Leurs résultats ont rapporté que **MLFFN** avec une configuration 3-5-2 prédit à la fois h et Nu avec des valeurs R de 0,9999. **ANFIS** a également été utilisé pour prédire les caractéristiques Nu et Δp dans un tube à faisceau plat en se référant à Re, au rapport longitudinal du pas au petit diamètre et au rapport transversal du pas au petit diamètre, [183]. La précision entre les valeurs numériques et les résultats du modèle **ANFIS** a été obtenue avec un **MRE** pour Nu et Δp moyen inférieurs à 1,9% et 2,97%, respectivement. Karami et al. [184] ont prédit le Nu en référence à Re et au taux de

torsion dans un échangeur de chaleur à condenseur refroidi par air équipé d'inserts en ruban torsadé utilisant **ANFIS**. Il a été signalé que les erreurs maximales des données de l'apprentissage et de test étaient respectivement de 0,111% et 2,378%. Le **MRE** des données de l'apprentissage et de test est en conséquence de 0,011% et 1,316%.

Les améliorations de transfert de chaleur induites par oscillation ont été largement utilisées dans les échangeurs de chaleur compacts, [185] et les échangeurs de chaleur à tube, [186]. Dans un travail connexe, le ***Nu*** a été prédit pour un flux annulaire oscillant en référence à quatre paramètres, à savoir, la cinétique ***Re***, l'amplitude sans dimension, les hauteurs de remplissage et le flux de chaleur, [187]. La structure du réseau a été optimisée pour la configuration 4-5-1. Les prévisions de réseau de ***Nu*** par RNA sont plus proches des valeurs expérimentales avec un écart d'environ 5%.

II.5.2. Estimation du facteur d'encrassement (R_{fo})

Les dépôts de matière sur les surfaces des tubes de l'échangeur de chaleur influenceront ses performances thermiques, [188]. Le facteur considéré pour les dépôts de matière s'appelle le facteur d'encrassement ***(R_{fo})***. Le RNA a été utilisé avec succès pour prédire le R_{fo} dans les échangeurs de chaleur, [189,190]. Le rendement thermique d'un échangeur de chaleur obtenu par l'approche analytique conventionnelle est supérieur à celui des valeurs expérimentales en raison de l'effet d'encrassement, [191]. L'estimation de R_{fo} basée sur RNA fournit une approche flexible en simulant les conditions réelles de fonctionnement expérimental. Aminian et Shahhosseini, [192] ont utilisé le modèle **MLFFN** pour prédire le R_{fo} du pétrole brut. Les ensembles de données d'apprentissage ont été extraits des résultats expérimentaux rapportés dans la littérature. Le réseau est constitué de trois neurones d'entrée représentant d_t, la vitesse brute et la température de la surface du tube. Il a été rapporté que la configuration du réseau avec une structure 3-5-6-1 prédit que le R_{fo} aurait un **MRE** de 26,23% par rapport aux résultats expérimentaux. Dans un travail ultérieur sur ce sujet, l'utilisation de **MLFFN** dans les préchauffeurs de pétrole brut en se référant à ***Re***, ***Pr*** et T_{sur}, [193]. Il a été rapporté que, **MLFFN** avec une configuration 3-8-1 prédit le R_{fo} avec une **MRE** de 14,05%, 22,47% et 15,83% pour l'apprentissage, les tests et la base de données globale, respectivement.

Lalot et Palsson, [194] ont prédit le R_{fo} d'un échangeur de chaleur à courants croisés utilisant l'RNA. Un modèle numérique a été utilisé pour générer les données d'apprentissage du réseau dans des conditions de propreté et d'encrassement. Les cinq

entrées du réseau sont T_i et To des fluides froids, T_i de fluide chaud, m de fluides froid et chaud. La couche de sortie n'a qu'un seul neurone représentant le R_{fo}. Il a été conclu que la modélisation RNA est assez sensible pour prédire le R_{fo} avec moins de temps de calcul, par rapport à la méthode conventionnelle d'estimation. Pour remédier à l'inconvénient de l'encrassement dans les échangeurs thermiques, Garcia a proposé une nouvelle stratégie de supervision utilisant l'RNA, [195]. La stratégie de supervision proposée permet de détecter, d'isoler et de gérer les défauts lors du contrôle de la température en boucle fermée d'un échangeur de chaleur, sur la base de techniques RNA statiques et dynamiques. La stratégie développée était divisée en trois modules. Le premier module vérifie la cohérence du système de supervision. Le second module surveille l'échangeur de chaleur pour détecter les conditions d'encrassement et permet de diagnostiquer les causes probables d'encrassement. Un troisième module prédit le temps de fonctionnement restant dans des conditions acceptables, associé à une tâche de prise de décision pour planifier l'organigramme de supervision. La stratégie de supervision développée est une nouvelle application de la technologie RNA pour détecter, isoler et prévoir l'encrassement des échangeurs de chaleur avec une bonne précision. Dans un autre travail, Romeo et Gareta, [196] ont utilisé une approche hybride RNA et logique floue pour contrôler le R_{fo} dans les échangeurs de chaleur de chaudières à biomasse. Il a été rapporté que la production d'électricité peut être améliorée d'environ 3,5% en utilisant une approche hybride RNA pour contrôler le taux d'encrassement dans les chaudières.

II.5.3. Estimation des facteurs de friction (f)

Beigzadeh et Rahimi, [197] ont prédit le Nu et f dans les tubes hélicoïdaux enroulés. Les expériences ont été réalisées avec un fluide chaud circulant dans des tubes enroulés qui est immergé dans un bain froid. Deux modèles ANN ont été développées pour prédire Nu et f. Le modèle **MLFFN** pour estimer Nu avait quatre paramètres d'entrée, à savoir Re, Pr, le rapport de courbure et le pas de la bobine. Dans un autre modèle **MLFFN** pour prédire **f** a trois paramètres d'entrée tels que Re, le rapport de courbure et le pas de bobine. Les valeurs Nu et f prévues à partir des modèles **MLFFN** ont été comparées aux résultats expérimentaux ainsi qu'aux prédictions théoriques rapportées dans la littérature. Le modèle **MLFFN** avec 9 neurones cachés a été sélectionné pour prédire Nu avec R^2 de 0,9993, **MSE** de 2,46 et **MRE** de 12,95%. De même, le modèle **MLFFN** avec 12 neurones cachés prédit f dans les

tubes avec R^2, **MRE** et **MSE** de 0,9997, 1,26% et $4{,}36.10^{-7}$, respectivement. Dans d'autres travaux, deux modèles **ANFIS** ont été développés pour prédire ***Nu*** et ***f*** dans des tubes enroulés, [198]. Le premier réseau avait quatre entrées, à savoir ***Re***, ***Pr***, la ration de courbure et le pas de la bobine pour prédire les valeurs ***Nu***. Alors que le deuxième réseau avait trois entrées représentant ***Re***, le rapport de courbure et le pas de la bobine pour prédire les valeurs ***f***. L'**ERM** des deux modèles **ANFIS** pour prédire ***Nu*** et ***f*** est de 6,24% et 3,54%, respectivement.

Zdaniuk et al. [199] ont utilisé l'approche du réseau à action directe pour prédire les ***j*** et ***f*** du débit d'eau dans des tubes droits à ailettes hélicoïdales internes. Les quatre entrées considérées dans leur travail sont les angles d'hélice (entre 25 et 48), le nombre d'ailettes (entre 10 et 45), les rapports hauteur-diamètre des ailettes (entre 0,0199 et 0,0327) et ***Re*** (entre 12 000 et 60 000). Les réseaux ont été formés avec des résultats expérimentaux obtenus à partir de la littérature. Il a été signalé que le réseau avec des fonctions log-sigmoïdes dans la première couche et une fonction de nœud linéaire dans la couche de sortie est l'architecture la plus avantageuse pour la prédiction de ***j*** et ***f*** dans des limites d'erreur acceptables. De même, Xie et al. [200] ont utilisé un **MLFFN** pour corréler ***Nu*** et ***f*** pour trois types d'échangeurs de chaleur en utilisant des générateurs à vortex en triangle, à ailettes et à ailettes longitudinales. La configuration **MLFFN** utilisée dans leur travail se compose de douze entrées représentant les paramètres géométriques (***Re***, ***N***, d_t, pas des ailettes, pas des tubes longitudinaux et transversaux des tubes, hauteur, largeur et longueur de la fente, longueur et hauteur du générateur de vortex et angle d'attaque) avec deux neurones de sortie représentant ***Nu*** et ***f***. Le réseau est optimisé pour une configuration 12-9-5-2. Les erreurs **MRE** et **RMS** maximales entre les données **PRN** et expérimentales se situent dans les écarts de 5% et 1,44%, respectivement.

Nasr et al. [201] a amélioré les performances des échangeurs de chaleur en utilisant des inserts en fil métallique. Dans leur travail, ***Nu*** et ***f*** ont été obtenus en utilisant deux modèles **MLFFN**. Le **MLFFN** avec quatre paramètres d'entrée dans la couche d'entrée représentant ***Re***, ***Pr***, ***e/dh*** et ***p/dh*** a été utilisé pour prédire ***Nu***. La structure de RNA pour prédire ***f*** se compose de trois paramètres d'entrée dans la couche d'entrée (***Re***; ***p/dh***; ***e/dh***) et ***f*** est le seul terme de sortie dans la couche de sortie. Le **MLFFN** avec une configuration 4-4-1 prédit le coefficient de transfert de chaleur avec une excellente valeur ***R*** de 1 et **MRE** de 1,78%. Le réseau avec une architecture 3-4-2-1

prédit le f avec **MRE** de 3,26 et R^2 de 0,9936. Dans un autre travail, les h et f dans les tubes ondulés combinés avec des inserts en ruban torsadé ont été prédits en utilisant deux modèles **MLFFN**, [202]. Deux **MLFFN** ont été développés avec cinq neurones dans la couche d'entrée (représentant Re, hauteur de l'ondulation/diamètre du tube, hauteur de l'ondulation/hauteur de l'ondulation, β et hauteur de la bande torsadée/diamètre du tube) et un neurone dans la couche de sortie (représentant h et f). Le **MLFFN** a été optimisé en configurations 5-13-5-1 et 5-9-8-1 pour prédire h et f, respectivement. Les prévisions **MLFFN** sont plus proches des résultats expérimentaux avec de bonnes valeurs **MRE** et R^2 (2,80% et 0,9966) et (0,36% et 1) pour h et f, respectivement. Dans un travail similaire, les Nu et f ont été prédits en utilisant **MLFFN** et **ANFIS** des bobines de fil et des inserts en ruban torsadé, [203]. Il a été signalé que l'**MRE** entre les résultats prévus et les données expérimentales était inférieur à 3% pour le **MLFFN** et à 1,5% pour l'**ANFIS**.

Tableau II.1 : Etudes rapportées pour l'analyse thermique des échangeurs de chaleur

	Auteurs [références]	Architectures réseau	Type d'échangeur de chaleur	Paramètres prévus
Modélisation des condenseurs	Islamoglu [108]	MLFFN	Condenseur sur tube	$\dot{Q}$
	Hayati et al. [109]	ANFIS	Condenseur sur tube	$\dot{Q}$
	Ertunc et Hosoz [110]	ANFIS	Condenseur évaporatif	Taux de rejet de chaleur du condenseur, T_{ref} sortant du condenseur, DBT et WBT de l'air sortant du condenseur
	Mohanraj et al. [111,112]	MLFFN	Condenseur à ailettes et à tubes	Destruction et efficacité exergétique
	Zhao et Zhang [113]	MLFFN	Condenseur à ailettes et à tubes	Capacité de chauffage, Δps dans les côtés réfrigérant et air
	Tian et al. [114]	MLFFN	Condenseur à flux parallèle	Capacité de l'échangeur de chaleur, côté air et réfrigérant Δps, T_{ref}
	Yang et al. [115]	MLFFN	Condenseur à ailettes et à tubes	Capacité de chauffage, côté air et côté réfrigérant Δps
Modélisation des serpentins de refroidissement et échangeurs de chaleur d'aspiration de la ligne de liquide	Islamoglu et al. [117]	MLFFN	Echangeurs de chaleur à aspiration de liquide	T_{ref} et $\dot{m}_{ref}$
	Heimel et al. [118]	MLFFN	Echangeurs de chaleur à aspiration de ligne liquide	$\dot{Q}$, $\dot{m}_{ref}$
	Kumlutas et al. [119]	MLFFN	Evaporateur	T_{sur} and $\dot{Q}$
	Yigit et Ertunc [120]	MLFFN	Fil sur la bobine de refroidissement du tube	T_a and RH
	Tahavvor and Yaghoubi [121]	MLFFN	Evaporateur	Epaisseur et densité du givre

Modélisation des échangeurs de chaleur à circulation	Akbari et al. [122,123]	MLFFN	Échangeur de chaleur à membrane run-around	Efficacité thermique sensible et latente
	Tan et al. [124]	MLFFN	Compact	Dans l'ensemble $\dot{Q}$
	Ermis [125]	MLFFN	Compact	Δp, h et Nu
Modélisation des échangeurs de chaleur à plaques	Selbas et al. [126]	MLFFN	Type de plaque	$(\dot{Q}, \varepsilon)$
	Peng et Ling [127]	MLFFN	Type de plaque	Δp côté froid et chaud, poids total et coût total
	Peng et Ling [128]	MLFFN	Type de plaque	j et facteurs
Modélisation des condenseurs à ailettes et à tubes	Pacheco-Vega et al. [130]	MLFFN	Ailettes et tube	$\dot{Q}$
	Pacheco-Vega et al. [131]	MLFFN	Ailettes et tube	$\dot{Q}$
	Ding et al. [132]	MLFFN	Chaleur ailettes et de tube	T_{ref} et T_a
	Wu et al. [133]	MLFFN	Refroidisseur à ailettes et à tubes	T_{CO2}, augmentation de pression, T_{air}, $\dot{Q}$
Modélisation des échangeurs de chaleur à coque et à tube	Xie et al. [135]	MLFFN	Coque et tube	$\dot{Q}$, ΔT entre l'huile et eau
	Mandavgane et al. [136]	MLFFN	Coque et tube	T de sortie d'eau froide et chaude
	Pandharipande et al. [137]	MLFFN	Coque et tube	T de sortie d'eau froide et chaude
	Kashani et al. [138]	MLFFN	Coque et tube	R_{f0}
	Duran et al. [139]	MLFFN	Coque et tube	Estimation du coût
Modélisation des capteurs solaires	Kalogirou et al. [141]	MLFFN	SWH (Assiette plate)	$\dot{Q}$, ΔT_w
	Kalogirou [142]	MLFFN	SWH (Assiette plate)	Production d'énergie solaire, quantité d'eau chaude par mois
	Kalogirou et al. [143]	MLFFN	SWH (Assiette plate)	T_w
	Kalogirou et al. [144]	MLFFN	SWH (Assiette plate)	Performance énergétique et maximum T_w
	Facao et al. [146]	MLFFN, RBFN	SWH (Assiette plate)	$\dot{Q}$
	Sozen et al. [147]	MLFFN	SWH (Assiette plate)	η_{the}
	Cetiner et al. [148]	MLFFN	SWH (Assiette plate)	$\dot{Q}.\dot{m}_w$
	Dikmen et al. [149]	MLFFN, ANFIS	SWH (Tube évacué)	η_{the}
	Farkas et Gecy-Vig [150]	MLFFN	SWH (Assiette plate)	T_w à huit endroits
	Caner et al. [151]	MLFFN	SAH	η_{the}
	Esen et al. [152]	MLFFN	SAH	η_{the} et T_a
	Benli et al. [153]	MLFFN	SAH	η_{the}

Modélisation des mélanges	Hosoz et al. [155]	MLFFN	Tour de refroidissement	Taux de rejet de chaleur, $\dot{m}$ d'eau d'appoint, T_w
	Gao et al. [156]	MLFFN	Tour de refroidissement	sortie de la tour, DBT et *RH* de l'air
	Gao et al. [157]	MLFFN	Tour de refroidissement	sortant du ruisseau
	Islamoglu et al. [158]	MLFFN	Tour de refroidissement	Sortie T_w, DT_w, η_{CT}
	Qi et al. [159]	MLFFN	Tour de refroidissement	Gravité de l'air, refroidissement
	Wu et al. [160]	MLFFN	Tour de refroidissement	ΔT, efficacité de refroidissement, h, coefficient de transfert de masse et perte d'évaporation, COP
	Hosoz et al. [161]	MLFFN	Refroidisseur évaporatif	Sortie T_w Du transfert de chaleur sensible et latente, DBT de sortie de l'air, température de la solution aqueuse de sortie, rapport du transfert de chaleur sensible au transfert de chaleur total, différence d'humidité entre l'entrée et la sortie.
	Kiran et Rajput [162]	MLFFN,ANFIS	Refroidisseur évaporatif	DBT et *RH*, masse d'eau évaporée, vitesse de refroidissement sensible et efficacité sortie T_a et ε
Modélisation des échangeurs de chaleur terre-air	Kumar et al. [164]	MLFFN	Echangeurs de chaleur Terre-air	Performances de chauffage et de refroidissement
	Zhang et Haghighat [165,166]	MLFFN	Echangeurs de chaleur Terre-air	Nu à trois endroits
	Gang et Wang [167]	MLFFN	Echangeurs de chaleur géothermiques	Température de sortie de l'échangeur de chaleur géothermique
Modélisation des échangeurs de chaleur des centrales	Krzywanski and Nowak [168]	MLFFN	Super radiateurs	h
	Hakeem et al. [169]	MLFFN	Rebouilleur de thermosiphon	T_0 de la chaudière
	Prieto et al. [170]	MLFFN	Condenseur	$\dot{Q}$
Modélisation des échangeurs de chaleur à usage spécial	Kocabas et al. [172]	MLFFN	Tube vortex	ΔT
	Uluer et al. [173]	MLFFN	Tube vortex	ΔT
	Dincer et al. [174]	MLFFN	Tube vortex	ΔT
	Amanifard et al. [175]	GMDH	Micro-canal	Nu et Δp
	Wijayasekara et al. [176]	Hybrid	Echangeur de chaleur à circuit imprimé	$\dot{Q}$ et Δp

Estimation des coefficients de transfert de chaleur	Jambunathan et al. [177]	MLFFN	Débit sur tubes (air)	h_{con}
	Ghajar et al. [178]	MLFFN	Tube horizontal avec trois configurations d'entrée	h
	Islamoglu et Kurt [179]	MLFFN	Canaux ondulés	Nu
	Colorado et al. [180]	MLFFN	Bobine hélicoïdale	Nu
	Mehrabi et al. [181]	ANFIS	Echangeurs de chaleur à double tube	h, intérieur et extérieur Δps
	Kamble et al. [182]	MLFFN	Tube horizontal	h et Nu
	Thaseen et al. [183]	ANFIS	Tubes à faisceau plat	Nu et Δps
	Karami et al. [184]	ANFIS	Condenseur refroidi par air avec inserts à tube torsadé	Nu
	Akdag et al. [185]	ANFIS	Tubes induits oscillants	Nu
Estimation du facteur d'encrassement	Aminian et Shahhosseini [192]	MLFFN	Echangeurs de chaleur	R_{fo}
	Aminian et Shahhosseini [193]	MLFFN	Echangeurs de chaleur	R_{fo}
	Lalot et Palsson [194]	MLFFN	Flux transversal	R_{fo}
	Garcia [195]	MLFFN	Type de bobine	Contrôle de R_{fo}
	Romeo et Gareta [196]	Hybrid	Echangeur de chaleur de chaudière	Contrôle de R_{fo}
Estimation du facteur de friction	Beigzadeh and Rahimi [197]	MLFFN	Tubes hélicoïdaux	Nu et f
	Beigzadeh and Rahimi [198]	ANFIS	Tubes hélicoïdaux	Nu et f
	Zdaniuk et al. [199]	MLFFN	Tube droit avec ailettes internes	facteur j et facteur f
	Xie et al. [200]	MLFFN	Générateurs de vortex	Nu et f
	Nasr et al. [201]	MLFFN	Bobine de fil	Nu et f
	Nasr and Khalaj [202]	MLFFN	Inserts de ruban de tubes ondulés	---
	Khalaj et al. [203]	MLFFN, ANFIS	Inserts de bobine de fil	Nu et f
Prédiction des coefficients de transfert de chaleur d'ébullition	Balcilar et al. [206]	MLFFN,GRNN RBFN	---	h_b et q_b
	Wang et al. [207]	MLFFN	---	h_b de fluides purs et mixtes
	Scalabrin et al. [208]	MLFFN	---	h_b
	Scalabrin et al. [209]	MLFFN	---	h_b
	Scalabrin et al. [210]	MLFFN	---	h_b
	Liu et al. [211]	MLFFN	---	h_b
	Alizadehdakhel et al. [212]	MLFFN	---	Δp
	Porto et al. [213]	Hybrid	---	h_b
	Wei et al. [214]	Hybrid	---	q_b
	Wen et al. [215]	RBFN	---	h_b

Prédiction du flux thermique critique	Mazzola et al. [217]	MLFFN	Eau	---
	Vaziri et al. [218]	MLFFN, RBFN	Eau	---
	Nafey [219]	MLFFN	Mélange eau de mer	---
	Cong et al. [220]	MLFFN	Eau, R113, R12	---
	Zaferanlouei et al. [221]	ANFIS	Eau	---
	Chen et al. [222]	Hybrid	Eau	---
	Wei et al. [224]	GNN	Eau distillée	---
	Moon et al. [225]	MLFFN	Eau	---
	Guanghui et al. [226]	MLFFN	Eau	---
Prédiction de la fraction de vide	Castillo et al. [227]	MLFFN	Echangeurs de chaleur géothermiques	---
	Zhang et al. [228]	MLFFN	Mini channe	---
	Malayeri et al. [229]	RBFN	Banc d'essai expérimental	---
Identification du régime d'écoulement	Mi et al. [234,235]	MLFFN	lingot, et le taux de désabonnement annulaire	---
	Tambouratzis and Pazsit [236,237]	MLFFN	lingot, et le taux de désabonnement annulaire	---
	Timung, and Mandal [238]	PNN	lingot, et le taux de désabonnement annulaire	---
	Roshani et al. [239]	MLFFN	lingot, et le taux de désabonnement annulaire	---
Prédiction des coefficients de transfert de chaleur de condensation	Demir et al. [240]	MLFFN	---	h_c
	Balcilar et al. [241]	MLFFN, RBFN GRNN,	---	h_c et Δp
	Balcilar et al. [242]	MLFFN	---	Δps pendant l'évaporation et la condensation
	Ermis et al. [243]	MLFFN	---	Capacité de stockage de chaleur
Contrôle des échangeurs de chaleur	Diaz et al. [247]	MLFFN	Echangeur de chaleur air-liquide	Contrôle de T_a
	Varshney and Panigrahi [248]	MLFFN	Echangeur de chaleur à tube à ailettes	Contrôle de T
	Abbassi and Bahar [249]	MLFFN	Condenseur évaporatif	Capacité thermique
	Nanayakkara et al. [250]	RBFN	Evaporateur	Capacité de refroidissement
	Vasickaninova et al. [251]	MLFFN	Echangeur de chaleur tubulaire	h et le débit volumique
	Hu et al. [252]	MLFFN	Echangeurs de chaleur HVAC	Températures de sortie d'eau glacée T_a
	Li et al. [253,254]	MLFFN	Evaporateur de système de climatisation	DBT et WBT
	Jahedi and Ardehali [255]	WNN-IIR	Echangeur de chaleur HVAC	Température et humidité
	Gang et al. [256]	MLFFN	Echangeur de chaleur géothermique	Température

II.6. Conclusion

La distribution temporelle du nombre d'études rapportées à l'aide de la méthodologie RNA d'analyse des échangeurs de chaleur est illustrée à la **Figure II.9**. D'après la **Figure II.9**, il est clair que le nombre d'enquêtes signalées dans ce domaine a progressivement augmenté au cours des dernières décennies. L'analyse thermique de l'échangeur de chaleur à l'aide d'RNA devient de plus en plus populaire auprès des chercheurs travaillant dans ce domaine.

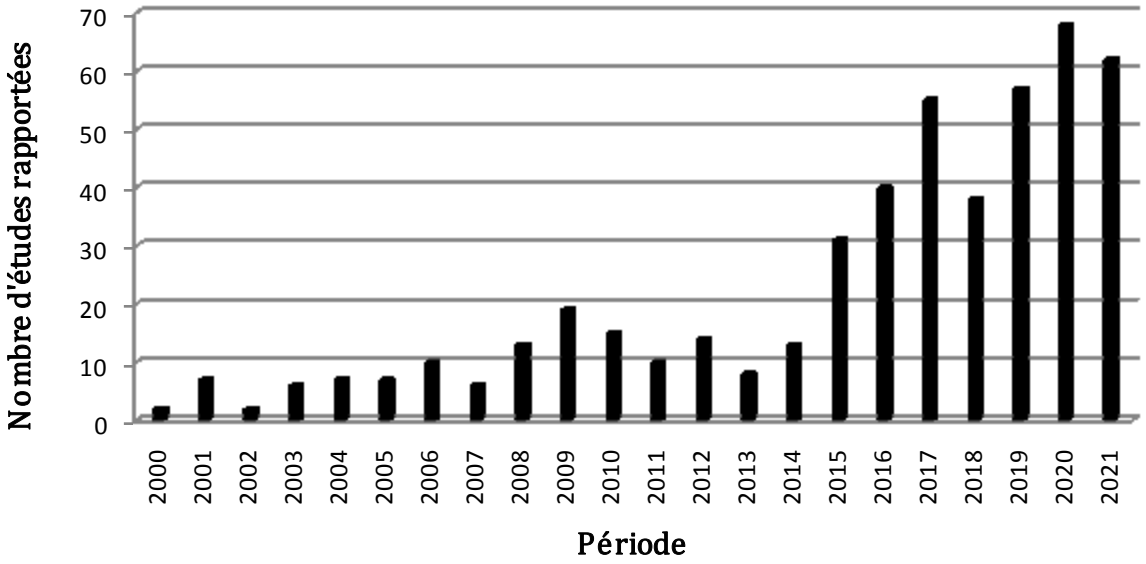


Figure II.9 : Applications de l'RNA pour l'analyse des échangeurs de chaleur [Science directe 2000-2021]

Chapitre III
Contribution à la modélisation de l'encrassement des échangeurs de chaleur

III. Introduction

L'accumulation de dépôts indésirables sur les surfaces des échangeurs de chaleur est généralement appelée encrassement. L'existence de ces dépôts résiste au transfert de chaleur et diminue ainsi l'efficacité de l'échangeur de chaleur dans les fluides. La superposition peut provenir de matières biologiques cristallines, de produits de réaction chimique, pour se rassembler avec décomposition par corrosion ou particules. La nature du dépôt dépend de la nature du fluide (liquide / gaz) passant dans l'échangeur de chaleur. Parfois, le problème d'encrassement est causé par une sorte de polluant dans le fluide, souvent à des concentrations extrêmement faibles, comme des particules solides ou des micro-organismes.

Le réseau de neurones artificiels établit des corrélations sur la base de données d'apprentissage, qui ne nécessitent aucune équation analytique explicite ou description du système. Les paramètres non linéaires relatifs aux processus d'échangeur de chaleur et de transfert de chaleur peuvent être liés entre eux grâce à l'utilisation de réseaux de neurones artificiels avec un minimum d'erreurs. Amrita Kumari et al. [257] ont proposé un modèle RNA qui évalue le processus d'apprentissage dans un réseau fournit une prédiction raisonnable et précise avec des données expérimentales, Reza Soleimani et al. [258]. Deux objectifs d'optimisation dans le développement de deux modèles de réseaux de neurones. Le calcul du flux maximal ainsi que la résistance minimale à l'encrassement tout au long de l'ultrafiltration des eaux usées industrielles a été anticipé au moyen de l'algorithme génétique (AG) et d'un réseau de neurone artificiel (RNA). Ehsan Davoudi et Behzad Vaferi, [259] ont élaboré une approche par RNA (réseau MLP) qui permet de prédire le facteur d'encrassement dynamique dans diverses conditions à partir de certaines variables facilement mesurables du système. Plusieurs approches ont été utilisées pour l'analyse thermique des échangeurs de chaleur, à savoir la revue composée de trois objectifs sur l'analyse thermique des échangeurs de chaleur: (1) Synthèse des études réalisées par RNA, (2) Comparaison des architectures de réseau, (3) identification des limites de recherche complémentaires et des besoins de l'RNA Mohanraj et al. L'application de nano-fluides dans les échangeurs de chaleur, [97], les problèmes de transfert de chaleur en génie nucléaire, [99], en plus de différentes techniques de calcul comme l'algorithme génétique (AG), optimisation de l'essaim de particules (PSO) et la machine a vecteurs de support (SVM), ont été utilisés avec succès pour estimer la résistance à l'encrassement

des échangeurs de chaleur. Afin de le rendre claire, on a organisé ce chapitre en trois contributions principales :

Dans la contribution préliminaire nous expliquerons tous les matériels et les méthodes traitées (RNA, SVM), la description de la base de données, leur collection et leur préparation, la procédure suivie pour sélectionner juste les entrées pertinentes, car elle revêt une grande importance dans la détermination de la qualité des deux modèles qui seront obtenus. Également nous expliquerons brièvement la méthodologie utilisée pour le développement de ces modèles, et la manière de choix de leurs paramètres.

Dans la deuxième contribution, il s'agit de la contribution à la modélisation de la résistance à l'encrassement dans les échangeurs-condenseurs par réseau de neurones artificiels direct et inverse. Ainsi, l'apport scientifique de cette recherche est de prédire la résistance à l'encrassement (RE*) dans l'échangeur de chaleur-condenseur fonctionnant de l'eau de mer de refroidissement d'une centrale nucléaire en utilisant l'approche RNA et en se basant sur des entrées et sortie sans dimension. Pour faciliter l'utilisation du modèle RNA développé, l'interface graphique Matlab sera développée pour faciliter le calcul pour les utilisateurs. En outre, une stratégie sera développée pour estimer les conditions de fonctionnement optimales (entrées) à partir de la résistance à l'encrassement (RE*) en utilisant le réseau de neurone artificiel inverse (RNAi). Finalement, nous interprétant et nous discuterons ces résultats.

Dans la troisième contribution de ce chapitre, une Application du réseau de neurone artificiel (RNA-MLP) pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides MgO-eau et CuO-eau. L'objectif de ce travail était de développer un modèle ANN-MLP pour prédire la résistance à l'encrassement des nano-fluides (MgO-eau et CuO-eau) à partir de données expérimentales dans l'échangeur de chaleur en fonction du temps, de la concentration volumétrique, du flux thermique, du débit massique et de température d'entrée. La détermination de l'effet de chacun des paramètres d'entrée sur la résistance à l'encrassement, en particulier l'effet des différentes concentrations de particules d'une part. Et d'autre part, c'est la plus haute précision du modèle RNA-MLP développé par rapport aux corrélations proposées pour la prédiction de la résistance à l'encrassement.

Contribution Préliminaire 1: Application par réseau de neurones artificiel et par machine à vecteur de support pour prédire l'encrassement des échangeurs de chaleur

III.1. Introduction

Un réseau de neurones est un processeur distribué massivement parallèle constitué d'unités de traitement simples, appelés nœuds qui exécutent certaines fonctions mathématiques, généralement non linéaires. Ce type de calcul non-algorithmique est caractérisé par un système qui ressemble à la structure d'un cerveau humain. Un des grands avantages de ces modèles est leur capacité à apprendre (stocker les connaissances expérimentales), généraliser (rendre les connaissances disponibles) ou extraire des règles automatiquement à partir de données complexes (Haykin 1998), [262].

Dans l'estimation de la résistance d'encrassement dans les échangeurs de chaleur, les RNA les plus couramment utilisés sont les perceptrons multicouches (MLP) qui utilisent la rétro-propagation.

Dans cette contribution on cherche à proposer une méthodologie d'optimisation pour atteindre le meilleur réseau de MLP; sur la base de presque tous les aspects de la modélisation RNA tels que la fonction d'activation, les données d'apprentissage, les algorithmes d'apprentissage, pré et post-traitement, le nombre de couches cachées et la taille du réseau.

L'objectif principal de cette recherche est de développer un modèle précis pour prédire la résistance d'encrassement dans l'industrie des échangeurs de chaleur.

III.1.2. Méthodologie d'optimisation d'un modèle neuronal

III.1.2.1. Sélection des paramètres RNA

Les paramètres RNA, tels que le nombre de neurones dans les couches d'entrée, les couches cachées et en sortie, l'architecture de réseau, la fonction de transfert, l'algorithme d'apprentissage, et le taux d'apprentissage doivent être sélectionnés pour développer un modèle RNA. La sélection correcte des données joue également un rôle majeur dans le succès de l'architecture RNA utilisée. Le nombre de neurones dans la couche d'entrée est généralement égal au nombre de paramètres qui affectent les performances des échangeurs de chaleur. La couche d'entrée distribue les valeurs à chaque neurone de la couche cachée. Une couche de neurones de traitement entre les couches d'entrée et de sortie est appelée couche cachée. Le nombre de couches cachées et le nombre de neurones des couches cachés peuvent varier en fonction de la précision requise. Le nombre de neurones dans la couche cachée, le nombre de couches cachées,

et les valeurs de vitesse d'apprentissage doivent être optimisé pour obtenir les résultats avec la précision requise. Le nombre de neurones dans la couche de sortie est généralement égal au nombre de paramètres sélectionnés pour prévoir les performances de l'échangeur thermique.

L'architecture de RNA est constituée d'un certain nombre d'unités appelées nœuds. Ces nœuds sont disposés en couches et sont interconnectés par des poids et des biais entre les couches. Habituellement trois étapes sont prises en compte dans les applications RNA, à savoir, (1) l'apprentissage, (2) la validation et (3) le test.

III.1.2.2. Apprentissage de l'RNA

RNA est formé à l'aide d'un ensemble de données d'entrée et de sortie connues et d'une méthode d'apprentissage appropriée pour exécuter une fonction en ajustant les valeurs du coefficient de pondération entre les neurones de traitement. Le processus d'apprentissage continue jusqu'à ce que la sortie de réseau corresponde à la sortie souhaitée. La modification des poids et des biais réduira l'erreur entre la sortie du réseau et la sortie souhaitée. Le processus d'apprentissage prend fin automatiquement lorsque l'erreur tombe en dessous d'une valeur déterminée ou que le nombre d'époches maximum est dépassé. La **figure III.1.1** décrit les étapes nécessaires à la formation de l'RNA utilisé pour l'analyse thermique d'un échangeur de chaleur, [263-266]. Les étapes à suivre sont répertoriées comme suit:

- Avant de collecter les données d'apprentissage, il faut trouver une bonne représentation des paramètres d'entrée et de sortie.

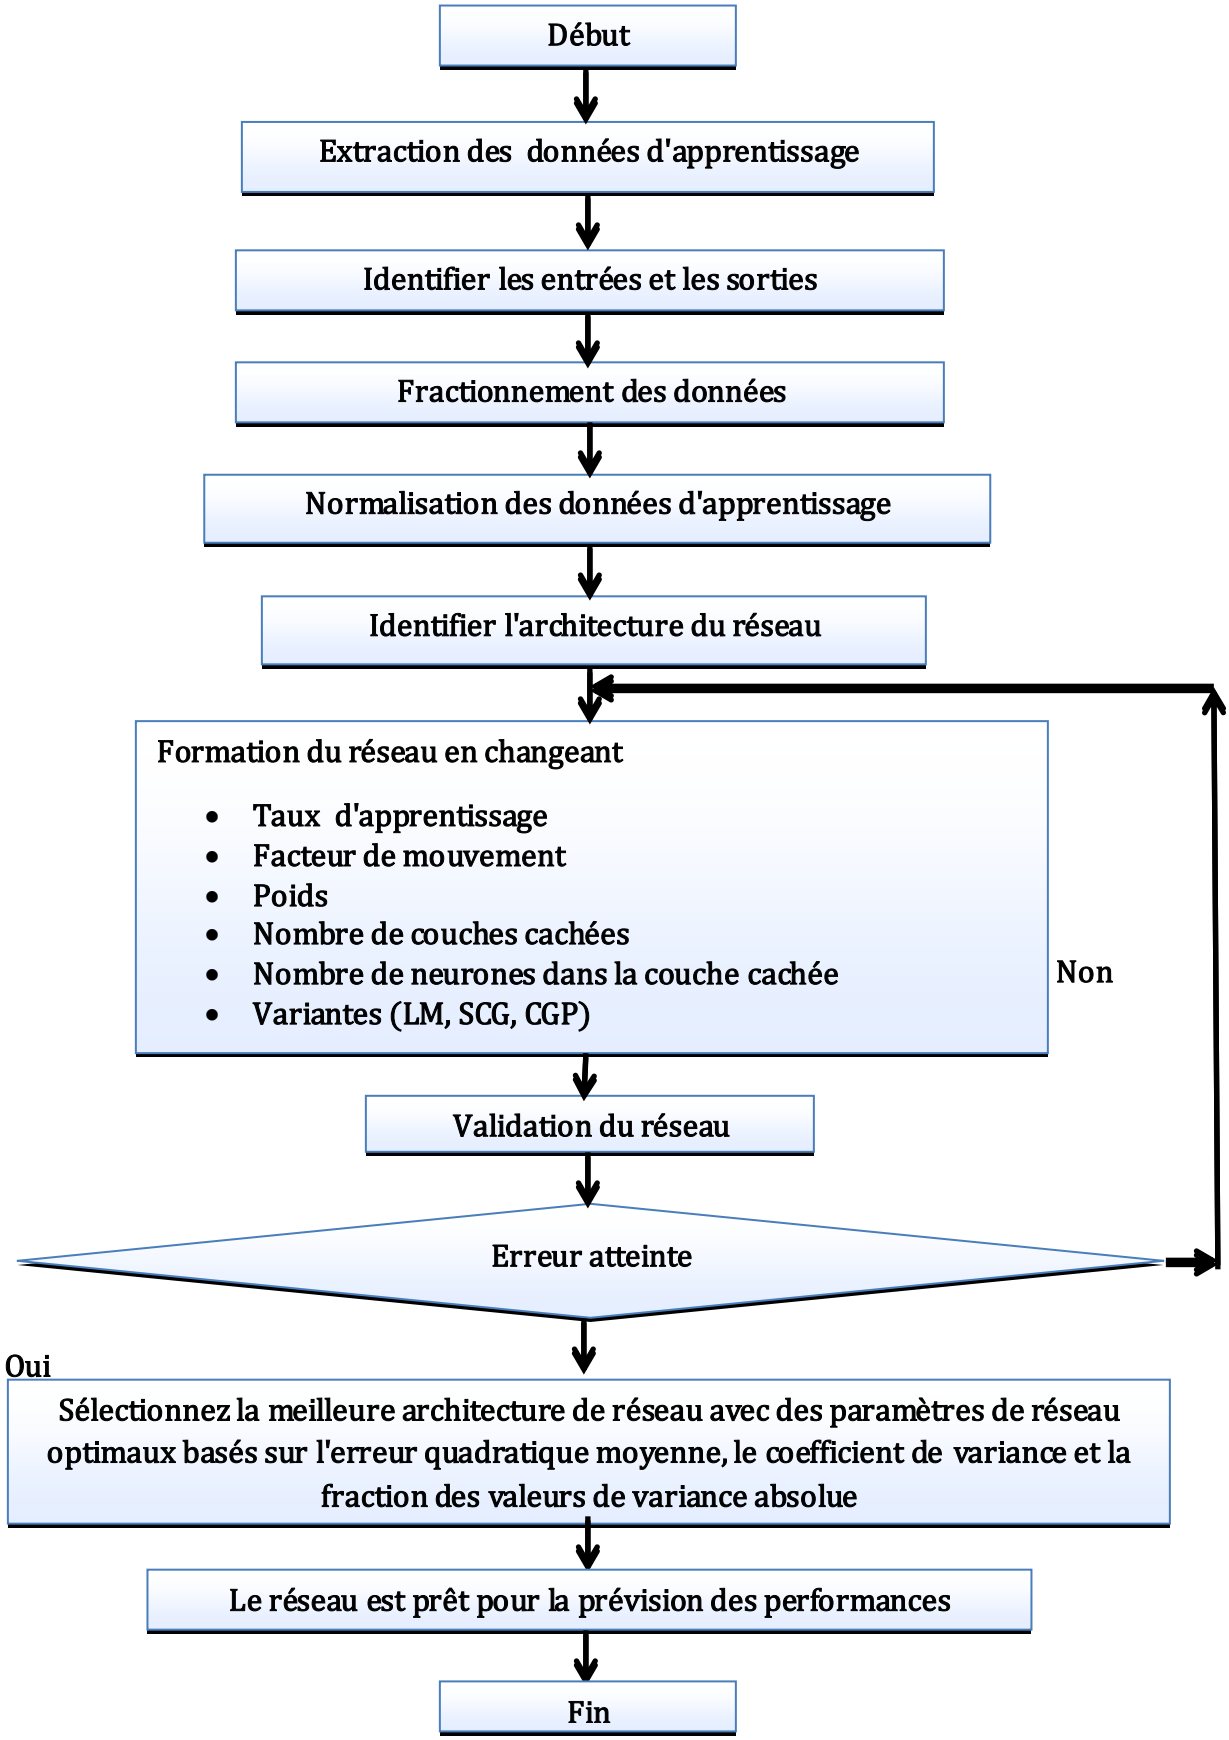


Figure III.1.1 : Organigramme des processus de formation RNA, [263-266].

L'identification des paramètres qui influencent la performance des échangeurs de chaleur (neurones dans la couche d'entrée) et les paramètres de performance d'un échangeur de chaleur à étudier (neurones dans la couche de sortie) doivent être sélectionnés pour la formation du réseau. Les paramètres constants sont négligés.

- Pour l'analyse des échangeurs de chaleur, il convient de prendre en compte l'influence de l'état mort (conditions ambiantes).
- Comme les réseaux sont formés sous supervision, les données d'entrée-sortie sont collectées à partir d'expériences ou de simulations numériques. Les données collectées ont été divisées en trois ensembles de données (apprentissage, validation, test). Les données pour l'apprentissage, la validation et les tests doivent être sélectionnées dans l'ensemble de la plage expérimentale.
- La normalisation des entrées et des sorties est effectuée dans la plage comprise entre 0 et 1 ou entre -1 et 1 (en fonction du type de données d'apprentissage). La normalisation des entrées et des sorties améliore la vitesse d'apprentissage du réseau.
- Développement d'un modèle RNA et définition des entrées et des sorties.
- Sélection de l'architecture du réseau en fonction de l'application concernée.
- Formation du réseau avec les valeurs d'entrée et de sortie normalisées à l'aide de la boîte à outils de réseau neuronal de MATLAB.
- Les paramètres de réseau (tels que les besoins en données d'apprentissage, le nombre de couches cachées, le nombre de neurones cachés et le taux d'apprentissage) doivent être optimisés pour obtenir des résultats avec une bonne précision.
- Extraction des résultats du réseau formé.

L'ensemble de données d'apprentissage est utilisé pour entraîner les poids dans le réseau de neurones afin de produire le résultat souhaité.

III.1.2.3. Test de réseau

Les performances du réseau sont évaluées à l'aide de paramètres statistiques, tels que le coefficient de détermination (R^2), le coefficient de corrélation (R), les valeurs moyennes quadratiques (RMS), l'erreur absolue moyenne (MAE), l'erreur relative absolue moyenne (MARE). Les paramètres du réseau ont été optimisés soit par la

méthode d'essais et d'erreurs, soit par de nouvelles techniques d'optimisation pour obtenir de meilleurs résultats.

Les réseaux de neurones sont caractérisés par leur topologie, les vecteurs de poids et les fonctions d'activation. Dans ce travail, un modèle MLP à trois couches a été utilisé, avec chaque couche étant constituée d'un certain nombre de neurones de calcul. Le schéma d'un réseau de neurones de type MLP à rétro-propagation est représenté sur la **Figure III.1.2**. Dans ce réseau toutes les informations sont transférées dans le sens avant seulement et il n'y a pas de boucle ou un cycle dans le réseau.

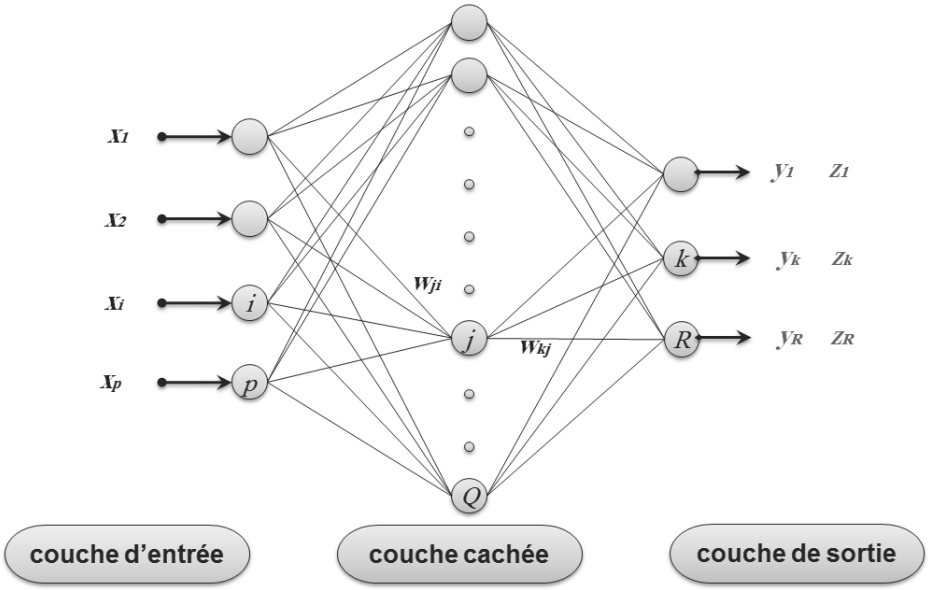


Figure III.I.2 : Schéma d'un réseau de type MLP (Bishop 1995), [267].

La procédure d'ajustement des poids est appelée rétro-propagation. Une procédure simplifiée pour le processus d'apprentissage des RNA est résumée ci-dessous:

Étape 1: Fournir au réseau des données d'apprentissage constituant les variables d'entrée et les sorties de cibles.

Étape 2: Évaluer l'accord de la sortie du réseau avec les sorties de cibles.

Étape 3: Adapter les poids de connexion entre les neurones de tel sorte que le réseau produit des meilleures approximations aux sorties de cibles souhaitées .

Étape 4: Poursuivre le processus d'ajustement des poids jusqu'au certain niveau de précision désirée.

III.I.2.4. Validation de réseau

Le jeu de données de validation est utilisé pour trouver les meilleurs paramètres de configuration et d'entraînement. L'ensemble de données de test est utilisé pour évaluer les paramètres des réseaux de neurones formés. Environ 80% des jeux de données sélectionnés au hasard sont attribués en tant que jeux de données d'apprentissage et les données restantes peuvent être utilisées pour tester et valider le réseau.

III.1.3. Description de méthode SVM

Les machines à vecteurs de support (SVM) sont une méthode d'apprentissage supervisé présentée pour la première fois en 1992 par Boser et al. [268], quelques années plus tard, elles ont été introduites par Cortes et al. 1995,[269] pour les cas de classification et en 2013 Vapnik et al. [270] ont été étendues et ajustées aux problèmes de régression pour mapper la relation non linéaire entre les entrées et les sorties afin de construire la fonction de régression dans l'espace des caractéristiques à haute dimension $\Phi(x)$, mapper vers l'espace d'origine et définir la fonction de noyau (Kernel) appropriée $K(x_i, y_i)$, où x_i est la valeur d'entrée, y_i est la valeur de sortie et $\{i = 1,..., m\}$ m est la taille de l'ensemble de données d'apprentissage $D = (x_i, y_i)$, [271]. La fonction de régression est conçue par $y = W^T . \Phi(x) + b$, où W est le vecteur de poids et b est le biais,[272].Les principaux avantages du modèle SVM sont à savoir, l'absence de minima locaux pendant la phase d'apprentissage, gérer la régression non linéaire, clairsemé, utiliser des fonctions de noyau, [272].

III.1.4. Matériels et méthodes

III.1.4.1. Base de données

La base de données a été collectée à partir de la littérature basée sur le phénomène d'encrassement d'un échangeur de chaleur à double tube fonctionnant avec deux liquides à contre-courant (eau, lait). Nous avons transformé cette base en nombres sans dimension comprenant la différence de température moyenne logarithmique, le nombre de Reynolds et le nombre de Prandtl des fluides entrant et sortant (chaud, froid) et la résistance à l'encrassement. Un résumé de la plage des différentes variables est présenté dans **Tableau III.1.1.**

Le nombre de données observées utilisées dans l'ARNA est de 200 qui sont divisées en trois sections:

- L'ensemble d'apprentissage (160 données) : Cet ensemble de données constitue la majeure partie des données, car à partir de cet ensemble de données, les poids des connexions des neurones sont ajustés au cours de l'apprentissage afin d'acquérir les connaissances du réseau. L'ensemble d'apprentissage couvre 80% de la base de données.
- L'ensemble de validation (20 données) : Cet ensemble de donnée est utilisé pour la vérification de la capacité de généralisation du réseau. L'ensemble de validation couvre 10% de la base de données.
- L'ensemble de test (20 données) : Cet ensemble de données est utilisé pour évaluer la performance de RNA dans des situations réelles. Cet ensemble de données est formé par les restes de la base de données, soit 10%.

Tableau III.1.1 : Gamme de variables Llinares Fontdevila, A, [273].

Fluide	Paramètre	Unité	Min	Max
	La différence de température moyenne logarithmique (ΔT*LM)	---	0,267	0,511
Fluide chaud	Nombre de Reynolds de fluide entrée chaude (Re*ec)	---	26942,150	29932,240
	Nombre de Reynolds de fluide sortie chaude (Re*sc)	---	28175,750	29934,370
	Nombre de Prandtl de fluide entrée chaude (Pr*ec)	---	3,636	7,304
	Nombre de Prandtl de fluide sortie chaude (Pr*sc)	---	2,788	5,391
Fluide froid	Nombre de Reynolds de fluide entrée froide (Re*ef)	---	1882,934	6736,126
	Nombre de Reynolds de fluide sortie froide (Re*sf)	---	2631,232	8877,425
	Nombre de Prandtl de fluide entrée froide (Pr*ef)	---	1,778	1,926
	Nombre de Prandtl de fluide sortie froid (Pr*sf)	---	1,778	1,881
	Résistance à l'encrassement adimensionnelle (FR*)	---	0,552	1,000

Avec :

- La différence de température moyenne logarithmique : $\mathbf{\Delta T*_{LM}} = \frac{2\,\Delta T_{LM}}{(Tec+Tsc+Tef+Tsf)}$

Fluide chaud (Eau) :

- Nombre de Reynolds de fluide (entrée, sortie) chaud :

  $\mathbf{(Re*ec, Re*sc)} = \frac{(4\rho Q)_{eau}}{(\pi\mu\,(d_2+d_1))_{eau}}$

- Nombre de Prandtl de fluide (entrée, sortie) chaud : $\mathbf{(Pr*ec, Pr*sc)} = \left(\frac{\mu\rho}{\alpha}\right)_{eau}$

Fluide froid (Lait) :

- Nombre de Reynolds de fluide (entrée, sortie) froid :

  $$\textbf{(Re*ef, Re*sf)} = \frac{(4\rho Q)_{lait}}{(\pi\mu(d_2+d_1))_{lait}}$$

- Nombre de Prandtl de fluide (entrée, sortie) froid : $\textbf{(Pr*ec, Pr*sc)} = \left(\frac{\mu\rho}{\alpha}\right)_{lait}$

III.1.5. Résultats et discussion

III.1.5.1. Résistance d'encrassement

Modélisation par (RNA) : L'objectif majeur et de savoir quelle est la meilleur architecture du réseau de neurones qui peux être capable de traiter la base de données disponible.

La conception et l'optimisation du RNA ont étés réalisées en cinq étapes. En bref :

- Au cours de la première étape, on a testé l'effet de séparation de la base de données sur l'optimisation du réseau.
- Au cours de la deuxième étape, les algorithmes d'apprentissages ont été testé pour trouver celles donnants la meilleure performance.
- Au cours de la troisième étape d'optimisation, on a testé les méthodes de prétraitement des données (méthodes de normalisations).
- La quatrième étape consistait a trouvé le nombre de couches cachées.
- Enfin, la dernière étape consiste à voir l'effet de nombre de neurones dans chaque couche cachée.

Toutes ces étapes ont été développées à l'aide du logiciel commerciale Matlab. La propriété émergente d'un RNA est sa capacité d'apprentissage. A partir d'un état quelconque, il va, en s'appuyant sur un algorithme d'apprentissage, adapter la valeur des poids synaptiques pour fournir une réponse vraisemblable vis-à-vis du problème traité.

Les paramètres du meilleur modèle RNA ont été déterminés sur la base de la méthode d'essai et d'erreur. Les résultats montrent que, le meilleur réseau de neurones à rétro-propagation de perception multicouche formé avec l'algorithme de *Levenberg-Marquardt* a été obtenu avec l'architecture des neurones {9, 9, 1} dans la couche d'entrée, caché et de sortie respectivement. La fonction de transfert tangente hyperbolique sigmoïde *Tansig* et linéaire *Purline* a été utilisée respectivement dans la

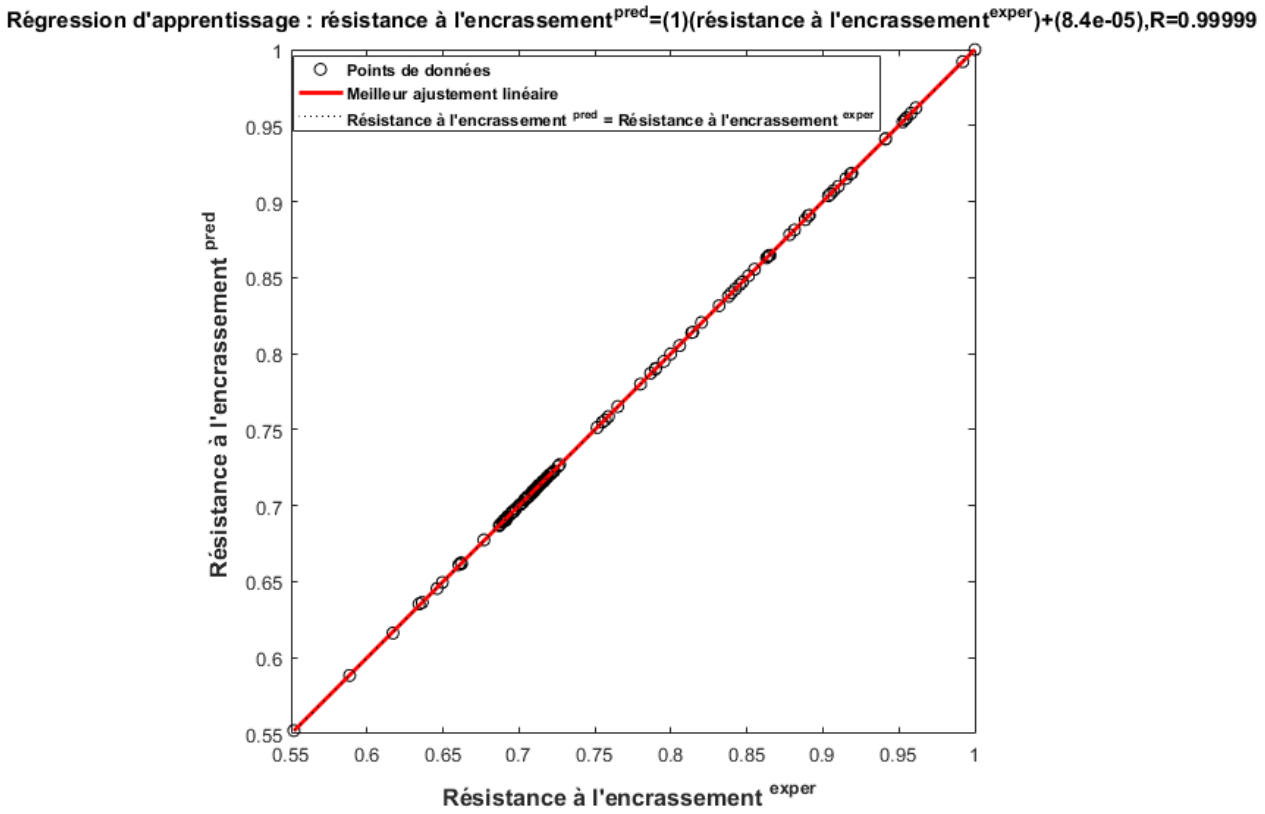
couche cachée et la couche de sortie. La courbe de régression et représentée sur la **Figure III.1.3.**

Où les performances statistiques du modèle RNA est présenté dans le **Tableau III.I.2** et son équation peut s'écrire comme suit:

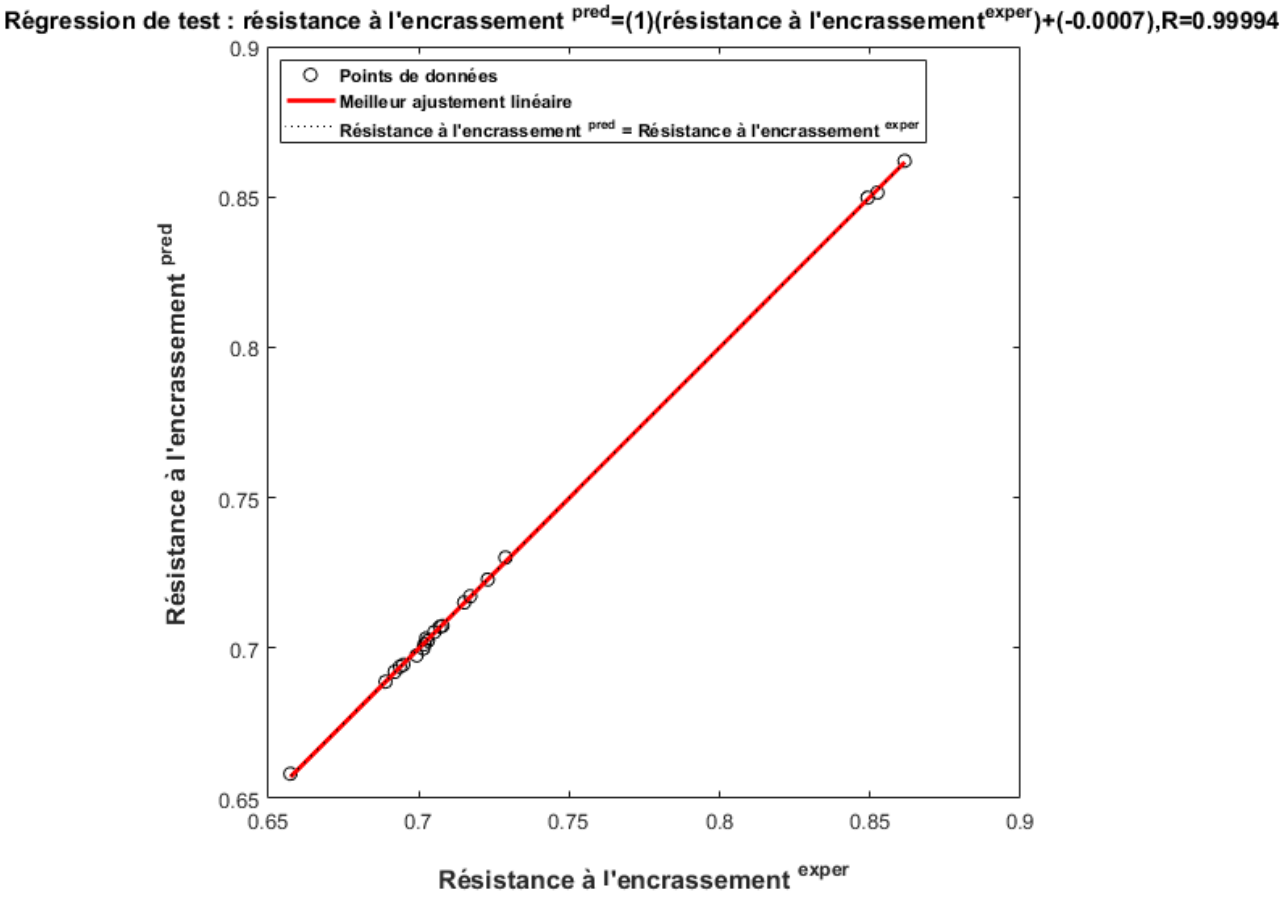
$$RE^{\star} = \sum_{n=1}^{n}\left[w_{ij(1.n)} \left(\frac{2}{1+\exp\left(-2\left(\left(\sum_{m=1}^{m} w_{i(n.m)} In_{(m)}\right)+b_{i(n)}\right)\right)} - 1 \right)\right] + b_j \qquad \text{(III.I.1)}$$

Tableau III.1.2: Performances statistiques de l'RNA

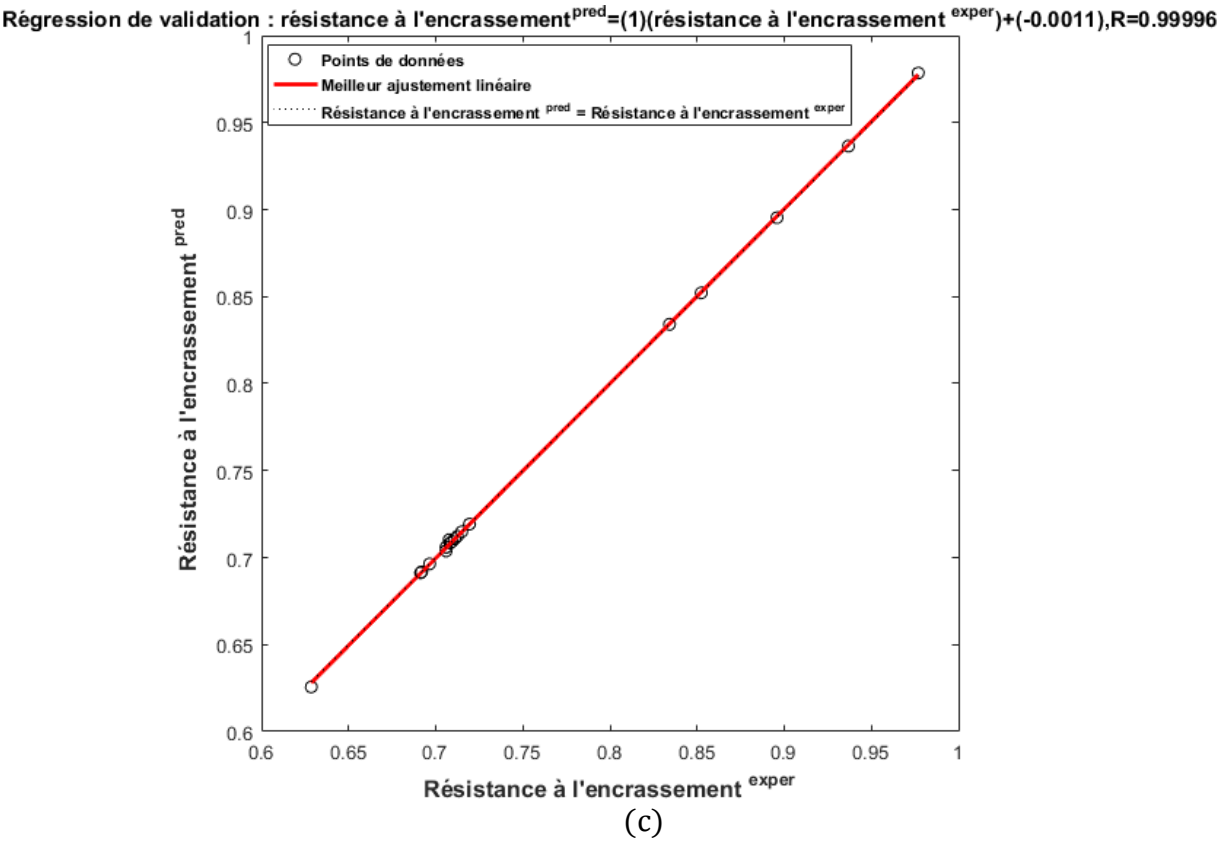
	Modèle	ERA_{Min} (%)	ERA_{Max} (%)	ERAM (%)	ET (STDEV) (%)	REQM	R
Apprentissage	RNA	2.2017e-05	0.1580	0.0259	0.2367	2.7841e-04	0.99999
Test	RNA	0.0024	0.2524	0.0593	1.6120	6.3663e-04	0.99994
Validation	RNA	5.1579e-04	0.2469	0.0556	0.1412	9.9209e-04	0.99996
Global	RNA	2.2017e-05	0.2524	0.0322	1.6120	3.7511e-04	0.99999



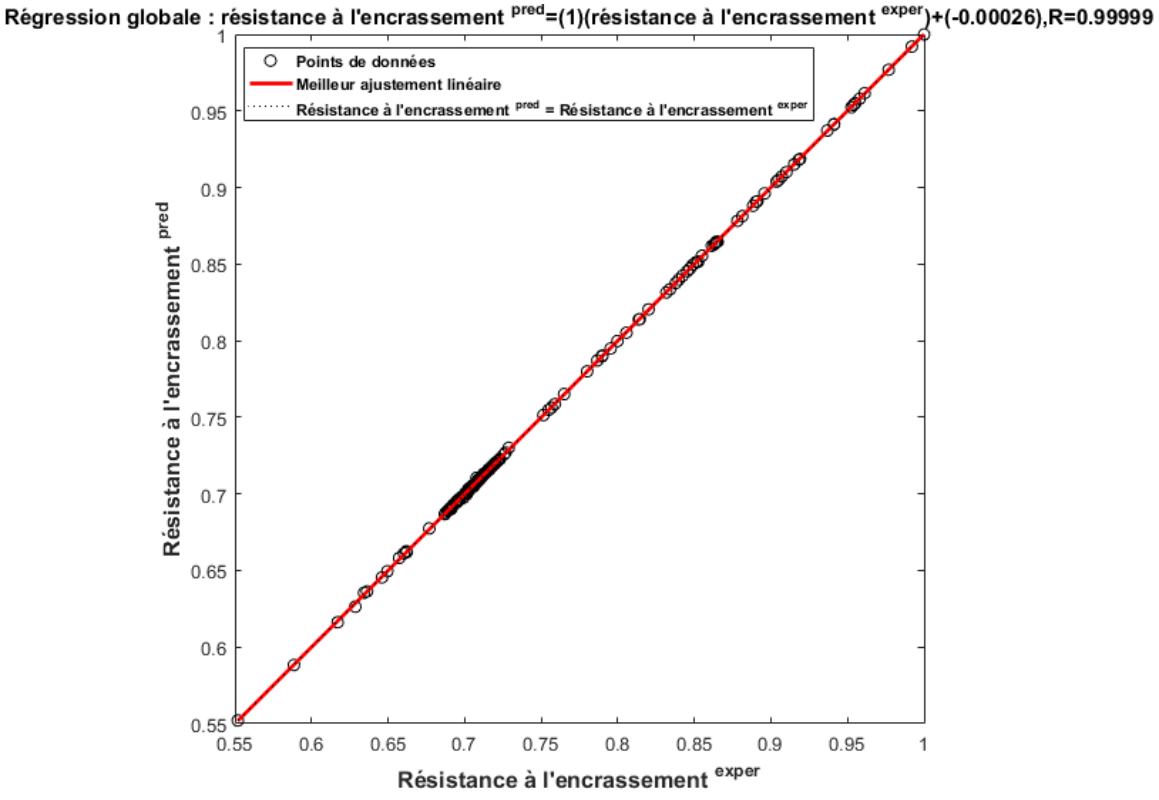
(a)


Régression de test : résistance à l'encrassement pred=(1)(résistance à l'encrassement exper)+(-0.0007),R=0.99994
Points de données
Meilleur ajustement linéaire
Résistance à l'encrassement pred = Résistance à l'encrassement exper
Résistance à l'encrassement pred
Résistance à l'encrassement exper
0.65
0.7
0.75
0.8
0.85
0.9

(b)


Régression de validation : résistance à l'encrassement pred=(1)(résistance à l'encrassement exper)+(-0.0011),R=0.99996
Points de données
Meilleur ajustement linéaire
Résistance à l'encrassement pred = Résistance à l'encrassement exper
Résistance à l'encrassement pred
Résistance à l'encrassement exper
0.6
0.65
0.7
0.75
0.8
0.85
0.9
0.95
1

(c)



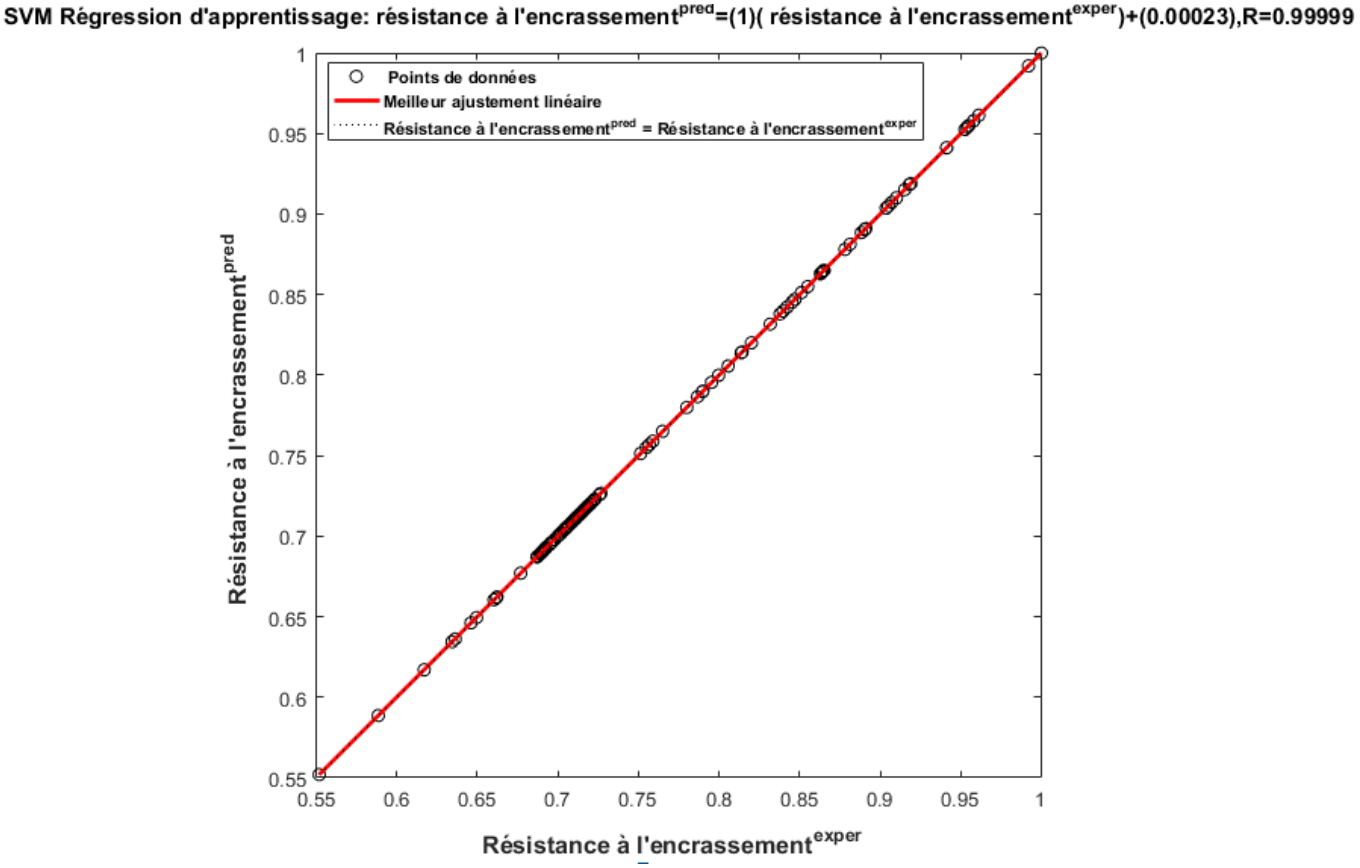
(d)

Figure III.I.3 : Graphe d'analyse de régression RNA entre l'expérimental et prédit de la résistance à l'encrassement adimensionnel : (a) Apprentissage, (b) Test, (c) Validation et (d) global

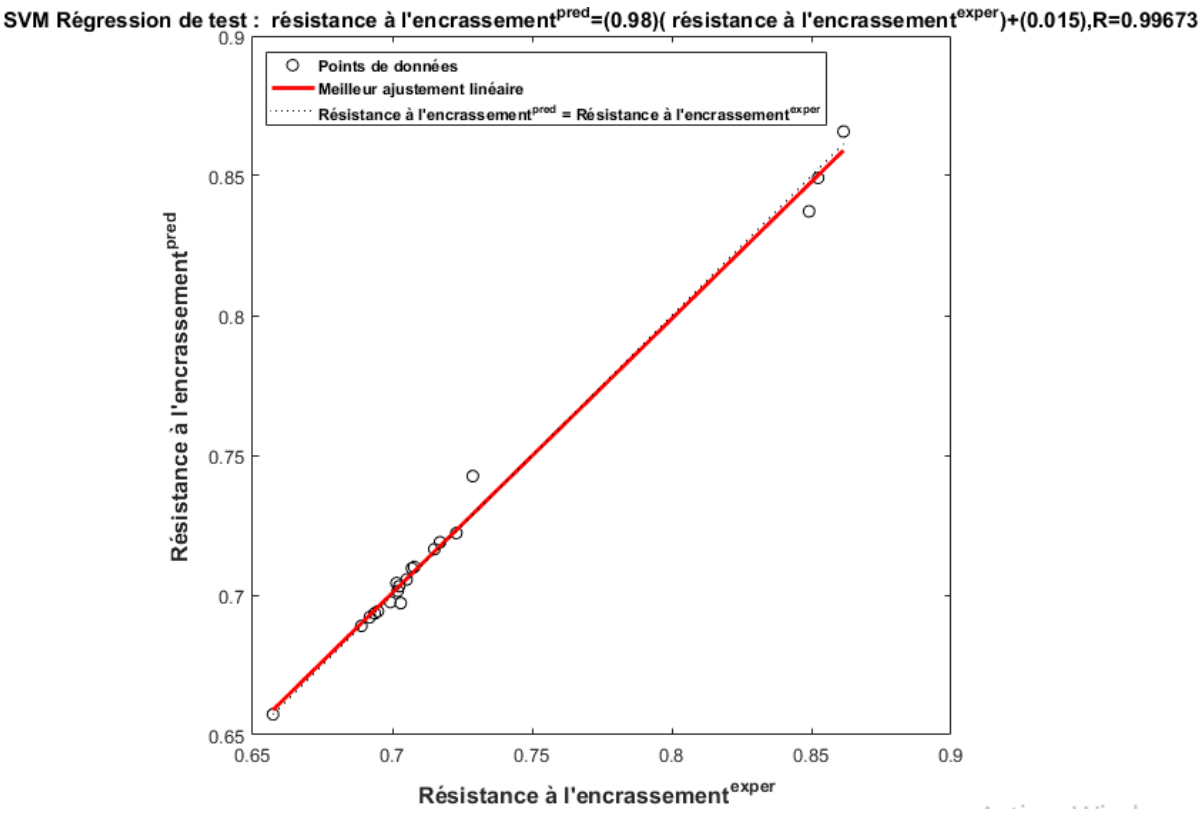
Modélisation par (SVM) : Un autre modèle a été développé basé sur l'approche SVM, le modèle est basé sur l'optimisation de ses paramètres à savoir, capacité (BoxConstraint) (C), le paramètre de largeur de noyau (Kernelscale) (γ), la quantité de vecteurs de support (QSV) et la fonction de noyau. La courbe de régression est représentée sur la **Figure III.1.4.** Où les performances statistiques du modèle SVM est présenté dans le **Tableau 1.III.3.**

Tableau III.1.3: Performances statistiques de SVM

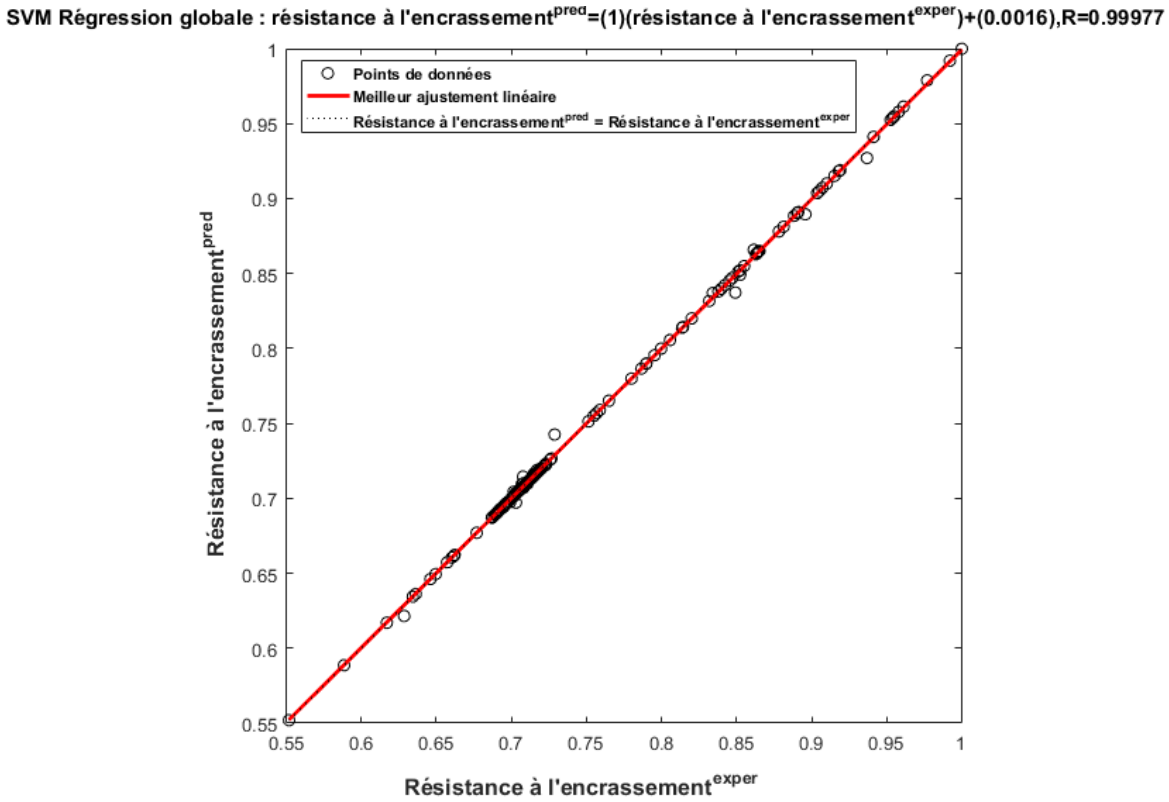
	Modèle	ERA_{min}(%)	ERA_{max}(%)	ERAM (%)	ET (STDEV) (%)	REQM	R
Apprentissage	SVM	0.0021	0.0492	0.0134	0.2040	0.0101	0.99999
Test	SVM	0.0076	1.8910	0.3644	0.3279	0.0679	0.99673
Global	SVM	0.0021	1.8910	0.0719	0.3279	0.0428	0.99977


SVM Régression d'apprentissage: résistance à l'encrassement^pred=(1)(résistance à l'encrassement^exper)+(0.00023),R=0.99999
Points de données
Meilleur ajustement linéaire
Résistance à l'encrassement^pred = Résistance à l'encrassement^exper
Résistance à l'encrassement^pred
Résistance à l'encrassement^exper
1
0.95
0.9
0.85
0.8
0.75
0.7
0.65
0.6
0.55
0.55
0.6
0.65
0.7
0.75
0.8
0.85
0.9
0.95
1

(a)


SVM Régression de test : résistance à l'encrassement^pred=(0.98)(résistance à l'encrassement^exper)+(0.015),R=0.99673
Points de données
Meilleur ajustement linéaire
Résistance à l'encrassement^pred = Résistance à l'encrassement^exper
Résistance à l'encrassement^pred
Résistance à l'encrassement^exper
0.9
0.85
0.8
0.75
0.7
0.65
0.65
0.7
0.75
0.8
0.85
0.9

(b)



(c)

Figure III.I.4 : Graphe d'analyse de régression SVM entre l'expérimental et prédit de la résistance à l'encrassement adimensionnel : (a) Apprentissage, (b) Test et (c) Global

Comme on peut le voir sur la **Figure III.I.3** et le **Tableau III.I.2** lemodèle RNA peut prédire les paramètres sélectionnés avec une grande précision par rapport aux modèles SVM avec erreur relative absolue moyenne minimale de (ERAM (%) =0.0322) par rapport au modèle SVM de (ERAM (%) = 0.0719) développé. Pour cette raison, une analyse de sensibilité de validation a été effectuée sur la base des paramètres RNA obtenus.

III.1.5.2. Détermination de l'importance de chaque variable d'entrée (étude de sensibilité)

La matrice des poids du réseau neuronal peut être utilisée pour déterminer l'importance relative des différentes variables d'entrée sur la variable de sortie **Tableau III.I.4**.

Garson (1991), [274] a proposé une équation basée sur la partition des poids de connexion :

$$I_J = \frac{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_o}\right|\right)}{\sum_{k=1}^{k=N_i}\left\{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_o}\right|\right)\right\}} \qquad \text{(III.1.2)}$$

Tableau III.1.4 : Paramètres statistiques obtenus pour le modèle RNA

N.N	W_1									Bais 1	W_2	Bais 2
	ΔT*LM	R_e*ec	R_e*sc	Pr*ec	Pr*sc	R_e*ef	R_e*sf	Pr*ef	Pr*sf		FR*	
1	0.0445224	-0.00107	-0.16923	0.098638	0.102295	-0.14622	-0.42934	-0.1284	-0.329	-1.19097	1.058386	
2	-0.03465	-0.36111	0.517313	-0.7032	0.453067	0.099964	0.188549	0.616337	-0.20817	-0.42979	1.32039	
3	0.759888	0.165207	-0.3755	0.118222	0.270435	-0.35768	0.128098	0.26431	-0.50434	-0.14705	1.390416	
4	1.622481	0.32448	-1.1855	-0.46051	2.431997	0.474712	-1.78385	-0.62894	-1.7331	2.586404	3.491194	
5	3.971925	0.166717	-1.07945	-1.85055	1.360893	0.229796	-1.16715	-1.32349	-0.83215	2.777264	-3.03746	-0.06062
6	3.534766	2.455042	-1.92852	-2.93715	2.287148	-0.30543	-3.79103	-2.59659	-2.04357	5.106276	4.364559	
7	0.715442	-0.09435	0.220235	-0.70515	-0.86486	0.576825	-1.12028	-1.01194	-0.12966	-0.24263	1.491956	
8	0.053866	-0.63036	0.623501	-1.01134	0.101417	0.32044	-0.21918	0.427324	0.24992	-1.45332	1.85164	
9	0.101667	0.064415	-0.03005	-0.43723	0.688951	0.752419	-0.62831	-0.40022	-0.11626	-1.77198	1.386791	

W_1: matrice de poids entre les couches d'entrée et cachées.
W_2: matrice de poids entre les couches cachées et de sortie.
Où I_j est l'importance relative de la $j^{ème}$ variable d'entrée sur la variable de sortie; N_i et N_h sont le nombre de neurones d'entrée et cachés, respectivement; w est les poids de connexion; les exposants i, h et o se réfèrent respectivement aux couches d'entrée, cachées et de sortie; et les indices k, m et n se réfèrent respectivement aux couches d'entrée, cachées et de sortie, [270].

L'importance relative des variables d'entrée calculées par **l'éq.(III.1.2)** est représentée sur la **Figure III.1.5**.

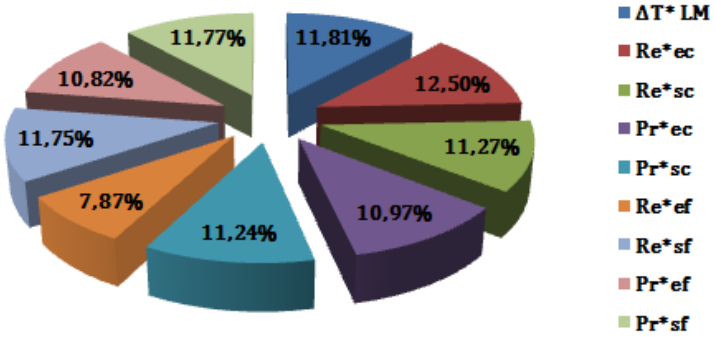


Figure III.1.5 : Importance relative (%) des variables d'entrée sur la valeur de la résistance à l'encrassement calculée

III.I.5.3. Interface pour la résistance à l'encrassement adimensionnelle

Le meilleur modèle RNA a été implémenté dans une interface utilisateur graphique conviviale conçue en utilisant le logiciel Matlab et présentée sur la **Figure III.1.6.** Cette interface peut calculer la sortie souhaitée en connaissant uniquement les entrées sélectionnées.

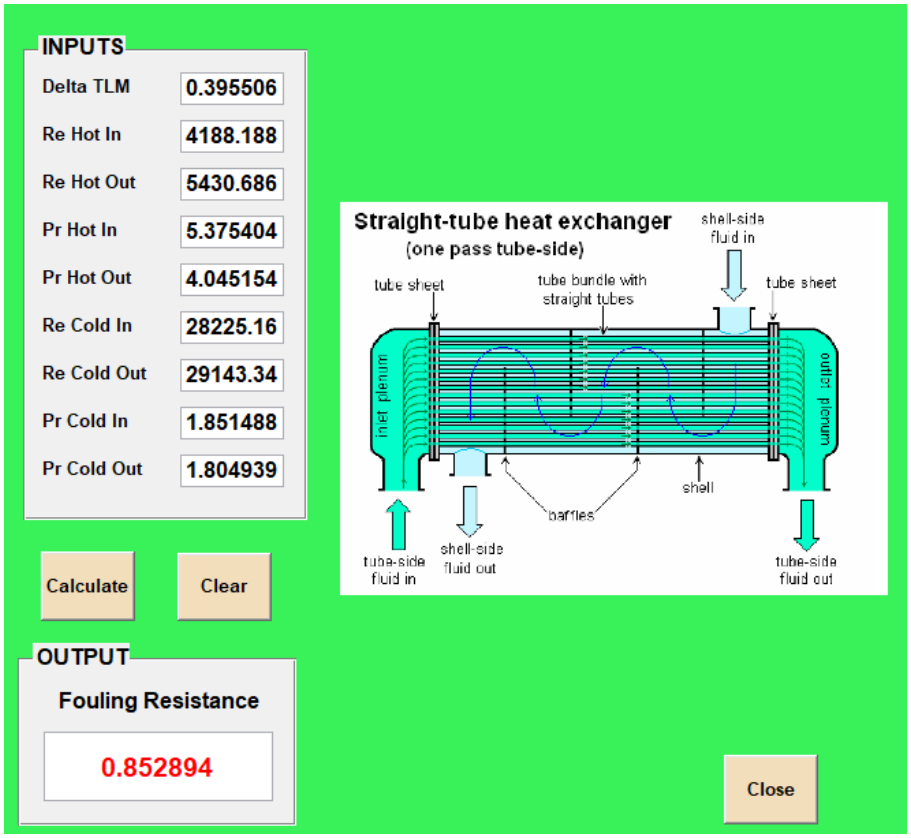


Figure III.1.6 : Interface MATLAB pour une résistance à l'encrassement adimensionnelle (Delta TLM: **ΔT*LM**; Re Hot In: **Re*ec**; Re Hot Out: **Re*sc**; Pr Hot In: **Pr*ec**; Pr Hot Out: **Pr*sc**; Re Cold In: **Re*ef**; Re Cold Out: **Re*sf**; Pr Cold In: **Pr*ef**; Pr Cold Out: **Pr*sf**; Fouling Resistance: **RE***)

III.I.6. Conclusion

Dans cette contribution préliminaire, une méthodologie pour choisir le meilleur modèle entre RNA et SVM pour prédire la résistance à l'encrassement a été présentée. La méthodologie commence par une recherche scientifique concernant l'analyse thermique de l'échangeur afin de sélectionner le modèle avec une complexité minimale, une performance optimale et un choix des paramètres respectifs (les entrées et les sorties, les fonctions d'activation, l'algorithme d'apprentissage, la technique de normalisation, les couches cachées et les nœuds cachés).

L'ensemble de données expérimentales de l'analyse thermique de l'échangeur de chaleur a été collecté à partir de la littérature tandis que la matrice d'entrée se compose de 9 entrées. Lesdeux modèles ont été évalués statistiquement en termes de ERAM et R, les résultats obtenus montrent que le RNA trouvé avec une très faible erreur (ERAM) de {0.0322} et un coefficient de corrélation élevé R de (0.99999), pour la résistance à l'encrassement de l'échangeur de chaleur. Il est conclu que le modèle RNAprouve que les valeurs estimées sont en bon accord avec les valeurs expérimentales.

Sur la base du modèle RNA, une analyse de sensibilité a été menée pour évaluer les effets des entrées sur la sortie, et les résultats montrent que toutes les entrées affectent fortement la sortie et leur choix était basé sur leur contribution à la phénoménologie étudiée.

Enfin, une interface utilisateur graphique conviviale a été conçue à l'aide du logiciel Matlab pour faciliter l'utilisation de ce modèle sans connaître aucun détail sur la phénoménologie ou le logiciel utilisé.

Contribution 2:
Contribution à la modélisation de la résistance à l'encrassement dans l’échangeur-condenseur par réseau de neurones artificiel direct et inverse

III.2.1. Introduction

De nombreux échangeurs de chaleur-condenseurs sont utilisés pour la réfrigération dans l'industrie de process. L'accumulation de dépôts indésirables sur les surfaces des échangeurs de chaleur est généralement appelée encrassement. L'encrassement est un problème majeur dans les condenseurs et les échangeurs de chaleur. L'existence de ces dépôts résiste au transfert de chaleur et diminue ainsi son efficacité. Tous les circuits industriels refroidis à l'eau sont affectés par le phénomène d'encrassement biologique consistant en la croissance de biofilms et la colonisation de plusieurs types d'organismes vivants.

Dans la littérature, peu d'articles sont publiés pour identifier le phénomène d'encrassement et ses impacts; peu ont essayé de les quantifier.

Río Calonge et al. [275] Ont essayé de montrer la croissance de l'encrassement biologique à l'intérieur des tubes de refroidissement d'un échangeur-condenseur, en maintenant la température de la paroi constante, en utilisant de l'eau de mer. Zubair, Syed. M. et al. [276] ont présenté une discussion basée sur les aspects économiques de l'encrassement des échangeurs de chaleur, qui sont suivis d'une analyse thermo-économique basée sur les risques d'un échangeur de chaleur. Casanueva, J. F. et al. [277] ont étudié le développement, la croissance et le contrôle de l'encrassement biologique marin dans les échangeurs de chaleur à condenseur afin d'évaluer l'impact des nouvelles réglementations sur une usine et un site particuliers. Qureshiet al. [278] Ont étudié l'effet de l'encrassement sur les caractéristiques thermo hydrauliques de l'échangeur de chaleur. Nebot, E. et al. [279] présentent un modèle pour prédire la valeur maximale de la résistance thermique de la couche d'encrassement sur les condenseurs de vapeur des centrales refroidies à l'eau de mer dans différentes conditions: effet de la vitesse de l'eau et du matériau du tube. Walker, Michael. E et al. [280]présentent une étude avec trois objectifs spécifiques : (1) quantifier l'impact économique de l'encrassement des condenseurs pour une centrale électrique de 550 MW avec des profils de température et de demande modérés, (2) déterminer l'impact relatif sur une centrale électrique identique avec des profils de température et de demande élevés, et (3) évaluation de l'impact relatif sur les condenseurs avec des paramètres de conception et des programmes de nettoyage variés. Ibrahim, Said M.A. et al. [25] ont fait une étude paramétrique qui illustre l'impact du facteur d'encrassement

du condenseur refroidi à l'eau de mer dans une plage de 0,00015 à 0,00035 m^2 K W^{-1}, et la température dans une plage de 15 à 30 °C. Zhong-bin Zhang et al. [281] ont proposé une nouvelle méthode pour calculer la conductivité thermique effective de l'encrassement particulaire basé sur le traitement d'image Image-Pro-Plus et calculé sa conductivité thermique en utilisant la méthode des éléments finis.

La technique du réseau de neurones artificiels (RNA) a été utilisée dans de nombreux domaines scientifiques tels que: dans l'énergie solaire par Rezrazi, A et al. [282], Laidi, M et al. [283]. Solubilité des médicaments solides par Abdallahelhadj, A et al. [284]. Un artificiel neural network (RNA) est utilisé pour développer des modèles prédictifs pour estimer les coefficients de diffusion moléculaire de divers gaz à des pressions multiples sur un large champ de températures Melzi, N et al. [285]. A partir des données expérimentales, trois modèles précis et fiables du phénomène d'encrassement dans trois types d'échangeurs de chaleur ont été développés par trois méthodes: le modèle Kern et Seaton, le modèle des moindres carrés partiels et le modèle de réseau neuronal artificiel. Faire une étude comparative basée sur quelques indices statistiques entre ces différents modèles en ce qui concerne la modélisation et la prédiction des pertes des performances des échangeurs de chaleur dues au phénomène d'encrassement Jradi, R et al. [286].

L'objectif principal de cette contribution est de développer un modèle précis pour prédire la résistance à l'encrassement dans l'échangeur de chaleur-condenseur en utilisant l'approche RNA. De plus, nous avons développé une stratégie pour estimer les conditions de fonctionnement optimales à partir du réseau neuronal artificiel inverse RNAi lorsqu'il est nécessaire d'obtenir un résultat optimal des entrées expérimentales à partir d'une résistance à l'encrassement adimensionnelle requise RE *.

III.2.2. Approche des réseaux de neurones artificiels

Malgré la puissance grandissante des calculateurs et la mise en œuvre d'approches théoriques de plus sophistiquées; plusieurs problèmes sont posés dans le cadre de ces recherches résistant encore aux algorithmes et aux méthodes classiques. Ces problèmes sont souvent dépendants de l'environnement et ne répondent pas à des modèles physiques connus.

En abordant par cette définition d'un RNA, reproduite du livre de Haykin, [287] on peut alors, imaginer les vastes domaines d'application potentielle des RNA, concevoir

l'intérêt qui leur a été réservé durant les deux dernières décennies, traduit par le nombre énorme de publications, et enfin comprendre pourquoi ils sont devenus un outil robuste de calcul scientifique dans plusieurs disciplines de sciences et d'ingénierie.

En raison de la disponibilité et la richesse bibliographique qui traite les fondements et les applications des RNA il est inutile de présenter avec détails toutes les notions théoriques des RNA, le lecteur peut consulter les excellents ouvrages de Dreyfus, [288], Engelbrecht, [289].

Par conséquent, nous examinons dans ce chapitre les facteurs majeurs affectant l'application réussie des RNA, en particulier les perceptrons multicouches (MLP, Multi Layer Perceptron) comme approximateurs universels de fonctions.

RNA est une technique de modélisation de données statistiques non linéaire adaptative consistant en des neurones artificiels interconnectés traitant des données en parallèle. Le type de réseau de perceptron multicouche (MLP) a été utilisé dans cette étude **Figure III.2.1**, et le processus d'apprentissage supervisé a été utilisé pour l'ajustement des paramètres de réseau.

III.2.2.1. Technique de normalisation

La normalisation de données se réfère à l'analyse et à la transformation des variables d'entrée et de sortie afin de minimiser le bruit, mettre en évidence des relations importantes, détecter les tendances, et aplatir la distribution de la variable pour aider le réseau de neurones dans l'apprentissage des motifs pertinents.

En général, la normalisation est accomplie pour assurer que toutes les variables utilisées dans les entrées du modèle ont la même importance au cours de l'apprentissage; par conséquent, la normalisation des données doit être comprise à partir de la limite inférieure à la limite supérieure de la fonction d'activation. Enfin, les sorties du réseau de neurones sont dénormalisées avant d'être présentées.

Les données d'entrée et de sortie ont été normalisées dans la plage de [$y_{min} = -1$, $y_{max} = 1$] en utilisant un algorithme mapminmax donné par **l'Eq. (III.2.1)** qui effectue une normalisation de la valeur maximale et minimale de chaque ligne Demuth, H et Beale, M, [290].

$$y = \text{map}\min\max(x) = \frac{(y_{max} - y_{min})(x - x_{min})}{(x_{max} - x_{min})} + y_{min} \qquad \text{(III.2.1)}$$

III.2.2.2. Fonction du transfert

La principale différence entre les divers types de réseaux réside dans le type de la fonction d'activation utilisée par les neurones cachés. Dans MLP, un type couramment utilisé par les neurones cachés a une fonction *sigmoïde tangente* montrée dans **l'Eq. (III.2.2)** ; et que, par les neurones de sortie une fonction de *purelin* représenté sur **l'Eq. (III.2.3)** (Vogl et al 1988; Rafiq et al, 2001), [291,292]:

$$f(w) = \frac{e^{w} - e^{-w}}{e^{w} + e^{-w}} \qquad \text{(III.2.2)}$$

Où w est la somme pondérée de l'entrée.

$$f(z) = z \qquad \text{(III.2.3)}$$

Et z est l'entrée à la couche de sortie.

Après avoir examiné un nombre considérable de réseaux de neurones structurés différemment, les RNA adéquats sélectionnés dans cet article ont une seule couche cachée avec 7 neurones et une couche de sortie avec un neurone. La couche cachée a une fonction de transfert *tansig*. La couche de sortie a une fonction de transfert de *purelin*. La structure typique de l'RNA est illustrée à la **Figure III.2.1.**

La formule mathématique qui relie les entrées à la sortie du réseau neuronal optimisé (RNA) est donnée dans **l'Eq. (III.2.4).**

$$\text{Sortie} = \text{RE}^{\star} = \sum_{n=1}^{n}\left[w_{ij(1.n)} \left(\frac{2}{1+\exp\left(-2\left(\left(\sum_{m=1}^{m} w_{i(n.m)} \text{In}_{(m)}\right) + b_{i(n)}\right)\right)} - 1 \right)\right] + b_{j} \qquad \text{(III.2.4)}$$

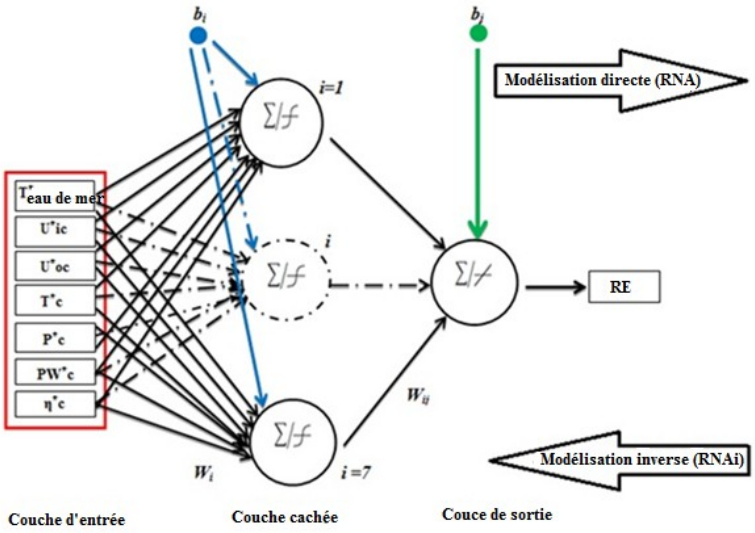


Figure III.2.1 : Structure de l'RNA de rétro-propagation à rétroaction à trois couches construit pour prédire le RE*

III.2.3. Procédure de modélisation

III.2.3.1.Collection de base de données

La base de données a été collectée à partir de la littérature basée sur le phénomène d'encrassement de l'eau de mer de refroidissement du condenseur d'une centrale nucléaire. Cette base de données expérimentale recueillie à partir de la littérature Ibrahim et al. [25] concernant l'encrassement des tubes de condenseur refroidissant par l'eau de mer d'une centrale nucléaire à réacteur à eau sous pression. Basé sur l'effet des conditions environnementales et du changement d'encrassement sur les performances thermiques du condenseur et le rendement thermique d'une centrale nucléaire. Nous transformons les entrées expérimentales dimensionnelles en une forme sans dimension. Cette base a été transformée en nombres sans dimension comprenant les différentes valeurs de la température de l'eau de mer de refroidissement du condenseur, du coefficient de transfert de chaleur global à l'intérieurdu condenseur, du coefficient de transfert de chaleur global à l'extérieurdu condenseur, de la température du condenseur, de la pression du condenseur, de la puissance de sortie, de l'efficacité thermique globale et de la résistance à l'encrassement.

Dans cet article, une méthodologie a été donnée pour sélectionner le modèle RNA pour prédire la résistance à l'encrassement du condenseur. L'objectif de cet article était de sélectionner le meilleur modèle. La méthodologie commence par une recherche approfondie afin de sélectionner un modèle avec une complexité minimale et des performances optimales. Le nombre de données observées utilisées dans l'RNA est de 600, qui sont divisées en trois sections: l'ensemble d'apprentissage (480 données), l'ensemble de test (60 données) et l'ensemble de validation (60 données). Les sous-ensembles de l'apprentissage, de test et de validation de l'RNA ont été obtenus en sélectionnant 80% de l'ensemble de données comme apprentissage, 10% de l'ensemble de données comme test et 10% de l'ensemble de données comme sous-ensembles de validation. Un résumé de la gamme des différentes variables est présenté dans le **Tableau III.2.1.**

Tableau III.2.1 : Gamme de variables adimensionnelles Ibrahim et al. [25].

Paramètres	Unité	Min	Max
Différentes valeurs de température de l'eau de mer de refroidissement du condenseur adimensionnelle **(T* eau de mer)**	---	0,6	1,2
Coefficient de transfert de chaleur global adimensionnel à l'intérieur du condenseur(**U*ic**)	---	0,49459	0,85544
Coefficient de transfert de chaleur global adimensionnel à l'extérieur du condenseur(**U*ec**)	---	0,67473	0,86058
Température du condenseur adimensionnelle (**T*c**)	---	1,04271	1,17221
Pression du condenseur adimensionnelle (**P*c**)	---	1,14258	1,44513
Puissance de sortie adimensionnelle (**PW*c**)	---	0,97831	0,99251
Efficacité thermique globale adimensionnelle du condenseur (**η*c**)	---	0,97738	0,99154
Résistance à l'encrassement adimensionnelle (**RE***)	---	0,00015	0,00035

Avec :

- La température réduite de l'eau de mer de refroidissement du condenseur : $T_{(eau\ de\ mer)} = T_{(eau\ de\ mer)\,exp}/25$. (25°C, la température ambiante),
- $U_{(i)c}$, le coefficient de transfert de chaleur global à l'intérieur du condenseur **sans** encrassement (f=0), déduit par extrapolation non linéaire, il peut être calculé pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique exponentielle : $U_{(i)c} = \mathbf{U_{(i)0}} \exp(-\alpha.f)$
- $U_{(e)c}$, le coefficient de transfert de chaleur global à l'extérieur du condenseur **sans** encrassement (f=0), déduit par extrapolation non linéaire, il peut être calculé pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique exponentielle : $U_{(e)c} = \mathbf{U_{(e)0}} \exp(-\beta.f)$
- T_c, la température du condenseur, déduite par extrapolation linéaire, elle peut être calculée pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique linéaire (f=0) : $T_c = \mathbf{T_0} + a.f$
- P_c, la pression du condenseur, déduite par extrapolation linéaire, elle peut être calculée pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique linéaire (f=0) : $P_c = \mathbf{P_0} + b.f$
- PW_c, la puissance nette de sortie, déduite par extrapolation linéaire, elle peut être calculée pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique linéaire(f=0) : $PW_c = \mathbf{PW_0} + c.f$
- η_c, l'efficacité réduite du cycle, déduite par extrapolation linéaire, elle peut être calculée pour chaque température $T_{(eau\ de\ mer)}$, par la relation empirique linéaire (f=0) : $\eta_c = \boldsymbol{\eta_0} + d.f$
- Résistance à l'encrassement réduit : $RE = \mathbf{RE_{exp}}/\mathbf{RE_\infty} = \mathbf{RE_{exp}}/1$

Le tableau **III.2.2** ci-dessous récapitule un exemple de calcule pour une température

$T_{(eau\ de\ mer)} = 15°C$, les valeurs de $U_{(i)0}$, $U_{(e)0}$, T_0, P_0, PW_0 et η_0.

Tableau III.2.2 : Exemple de calcule pour une température $T_{(eau\ de\ mer)} = 15°C$

$T_{eau\ de\ mer}$ (°C)	15
$U_{(i)0}$ (W/m²K)	1236.45
$U_{(e)0}$ (W/m²K)	1178.502
T_0, (°C)	31.6268
P_0 (bar)	0.04569
PW_0 (kW)	999644.52
η_0 (%)	37.117

Donc :

- Les différentes valeurs de température de l'eau de mer de refroidissement du condenseur adimensionnelle $T^*eaudemer = \frac{Teaudemer_{exp}}{25}$
- Le coefficient de transfert de chaleur global adimensionnel à l'intérieur du condenseur ($U^*ic = \frac{Uic_{exp}}{U_{(i)0}}$)
- Le coefficient de transfert de chaleur global adimensionnel à l'extérieur du condenseur ($U^*ec = \frac{Uoc_{exp}}{U_{(e)0}}$)
- La température du condenseur adimensionnelle ($T^*c = \frac{Tc_{exp}}{T_0}$)
- La pression du condenseur adimensionnelle ($P^*c = \frac{Pc_{exp}}{P_0}$)
- La puissance de sortie adimensionnelle ($PW^*c = \frac{PWc_{exp}}{PW_0}$)
- L'efficacité thermique globale adimensionnelle du condenseur ($\eta^*c = \frac{\eta c_{exp}}{\eta_0}$)
- La résistance à l'encrassement adimensionnelle $RE^* = \frac{RE_{exp}}{RE_\infty} = \frac{RE_{exp}}{1}$

La différence entre les valeurs observées et prédites a été filtrée à travers le système et a été utilisée pour ajuster les connexions entre les couches, améliorant ainsi

les performances. La racine de l'erreur quadratique moyenne (REQM) est le principal critère pour évaluer la performance de l'RNA, qui est définie comme suit: [293,294].

$$REQM = \left[\frac{1}{n}\sum_{i=1}^{n}\left(y_i - y_i^t\right)^2\right]^{\frac{1}{2}} \quad \text{(III.2.5)}$$

La qualité statistique de l'RNA pour les trois ensembles d'apprentissage, de test et de validation a ensuite été évaluée en utilisant le coefficient de détermination (R^2), l'erreur absolue relative (EAR), l'erreur en pourcentage absolue moyenne (ERAM), l'erreur quadratique moyenne (EQM), facteur de précision (A_f), facteur de biais (B_f) et critères d'acceptabilité K et K '.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(y_i - y_i^t\right)^2}{\sum_{i=1}^{n}\left(y_i - y_0\right)^2} \quad \text{(III.2.6)}$$

Avec:

$$y_0 = \frac{1}{n}\sum_{i=1}^{n}\left(y_i - y_i^t\right) \quad \text{(III.2.7)}$$

$$EQM = \frac{1}{n}\sum_{i=1}^{n}\left(y_i - y_i^t\right)^2 \quad \text{(III.2.8)}$$

$$ERA_i(\%) = \left[\frac{\left\|y_i\right| - \left|y_i^t\right\|}{\left|y_i\right|}\right] \times 100 \quad \text{(III.2.9)}$$

$$ERAM(\%) = \frac{1}{n}\sum_{i=1}^{n}\left[\frac{\left\|y_i\right| - \left|y_i^t\right\|}{\left|y_i\right|}\right] \times 100 \quad \text{(III.2.10)}$$

III.2.3.2. Critères statistiques

La fiabilité et la précision des modèles, développés à partir des méthodes d'intelligence artificiels, reposent sur diverses quantités statistiques : Erreur quadratique moyenne (EQM); Erreur absolue moyenne(EAM); Erreur quadratique relative moyenne (EQMR); Erreur relative absolue moyenne (ERAM); Coefficient de détermination (R^2);Coefficient de corrélation (R); Facteur de précision (A_f) et facteur de biais(Bf). Soleimani et al. [295]

- **Facteur de biais(B_f) et facteur de précision (A_f) :**

Bon modèle	$B_f = 0.9 — 1.05$
Modèle acceptable	$B_f = 0.7 — 0.9$

Utiliser avec précaution	$B_f = 1.06 — 1.15$
Modèle inacceptable	$B_f < 0.7$ et $B_f > 1.15$

Ross (1996) a proposé deux indices différents pour la détermination de la performance du modèle. Le facteur de biais (B_f) pour lamesure de la concordance globale entre les valeurs prédites et les valeurs observées. Il indiquera si, et dans quelle mesure, les prévisions se situent au-dessus ou au-dessous de la ligne d'équivalence. Une pondération égale est donnée à la sur-prédiction, ou la valeur prédite est supérieure à la valeur observée, et à la sous-prédiction. Le B_f est montré dans **l'éq. (III.2.11)**, [296].

$$B_f = 10^{\left(\frac{\sum_{i=1}^{n} \log \frac{y_i^t}{y_i}}{n}\right)} \qquad \text{(III.2.11)}$$

Un accord parfait entre les valeurs observées et les valeurs prédites donnerait un B_f de 1. Une valeur supérieureà 1 indiquerait que, en moyenne, les prédictions étaient plus grandes que les valeurs observées et représenteraient un modèle à sécurité intrinsèque ; par exemple un B_f de 1.2 indiquerait que les prévisions étaient 20% plus grandes que les valeurs observées.

Une valeur inférieure à 1 indiquerait un modèle à sécurité intrinsèque ou, en moyenne, les prévisions étaient plus courtes que celles observées. Le B_f est maintenant largement utilisé comme mesure de la performance du modèle et constitue un critère commun pour la comparaison de différents modèles. Dans le calcul du B_f, les prédictions sur (+) et sous(-) peuvent s'annuler. Ils ne montrent donc pas les erreurs absolues dans le modèle. Ceci peut être réalisé en utilisant le facteur de précision (A_f). Ceci est basé sur une équation similaire à (III.2.11) mais ignore si la différence entre la valeur prédite et la valeur observée est positive ou négative :

$$A_f = 10^{\left(\frac{\sum_{i=1}^{n} \left|\log \frac{y_i^t}{y_i}\right|}{n}\right)} \qquad \text{(III.2.12)}$$

Toutes les différences étant désormais positives, la valeur de à A_f sera toujours égale à (si l'accord est parfait) ou supérieur à un. Une précision de 1.5 signifie qu'en moyenne, la valeur prédite est différente de 50% (plus petite ou plus grande) de la valeur observée.

En outre, les critères suggérés par les chercheurs ont été utilisés pour assurer une plus grande validité des modèles développés. Ces critères statistiques sont donnés comme suit :

$$K = \frac{\sum y_i^t y_i}{\sum \left(y_i^t\right)^2} \qquad \text{(III.2.13)}$$

$$K' = \frac{\sum y_i^t y_i}{\sum \left(y_i\right)^2} \qquad \text{(III.2.14)}$$

Où $0{,}85 \leq K \leq 1{,}15$; $0{,}85 \leq K' \leq 1{,}15$ deux critères d'acceptabilité.

y_i représente le $i^{ème}$ test entraîné ou la valeur de sortie de validation, et y_i^t représente la valeur cible correspondante, n étant le nombre de vecteurs d'entrée.

III.2.3.3. Modélisation avec des réseaux de neurones

L'objectif de cette modélisation est de construire un modèle pour prédire la résistance à l'encrassement dans l'échangeur-condenseur. RNA a été choisie comme principal outil de modélisation pour effectuer la tâche.

Différentes valeurs de la température de l'eau de mer de refroidissement du condenseur sans dimension, coefficient de transfert de chaleur global intérieur sans dimension, coefficient de transfert de chaleur global extérieur sans dimension, la température du condenseur sans dimension, la pression du condenseur sans dimension, la puissance de sortie sans dimension et de l'efficacité thermique globale sans dimension étaient des arguments d'entrée pour le réseau (variables indépendantes), tandis que la résistance à l'encrassement sans dimension était un argument cible (variable dépendante). La structure de la base de données utilisée pour le modèle est présentée dans le **Tableau III.2.3** et la **Figure III.2.2.**

Tableau III. 2.3 : Structure du RNA

Type de réseau	Nombre de neurones dans la couche cachée	Fonction de transfert des neurones de la couche cachée	Fonction de transfert des neurones de la couche de sortie	Algorithme d'apprentissage	Nombre d'itérations ou de cycles
MLP 2 couches	7 neurones	Sigmoïde tangentiel	Fonction d'identité	Levenberg-Marquardt	631

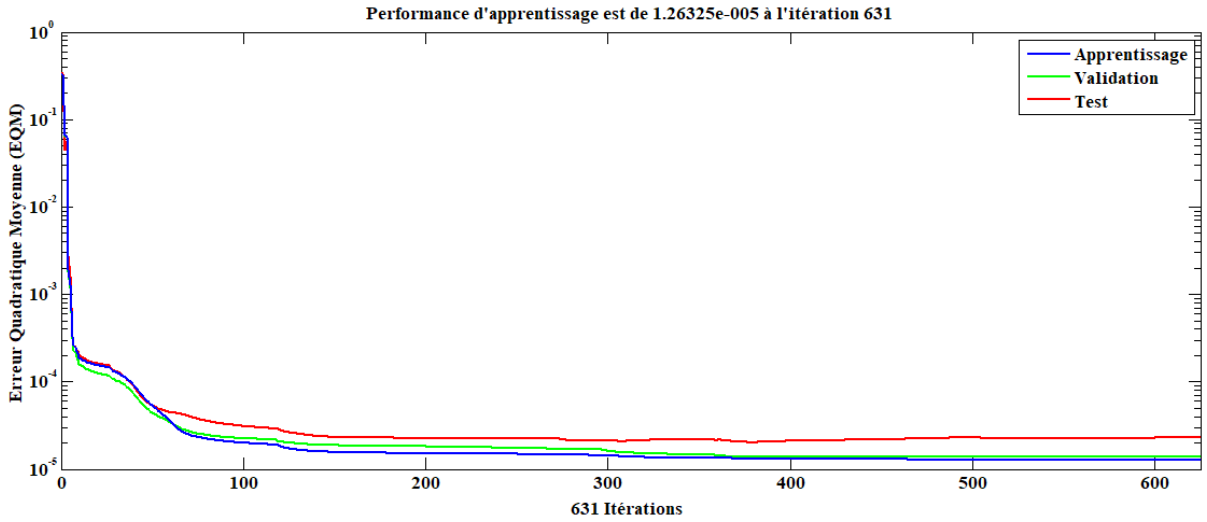


Figure III.2.2 : Apprentissage avec le diagramme fonctionnel TRAINLM

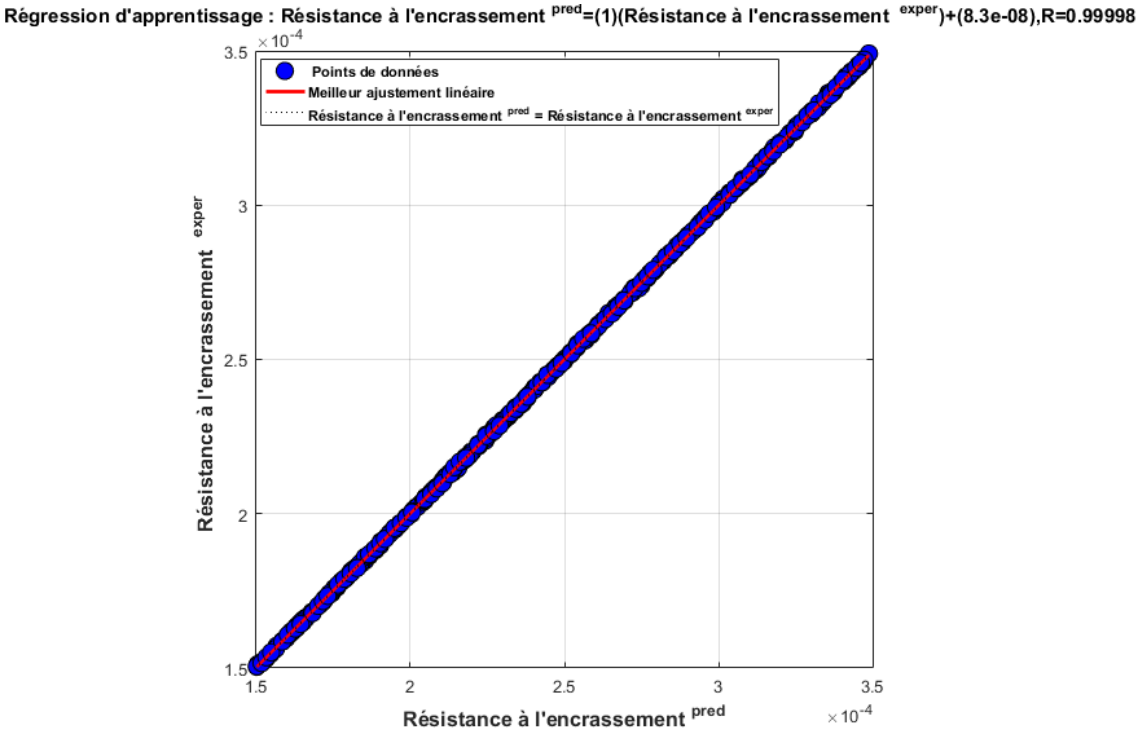
Dans cette partie nous avons listées toutes les étapes importantes qui ont conduit à la solution de l'optimisation des réseaux de neurones. Les paramètres suivants ont été examinés et optimisés lors du développement du meilleur réseau pour la prédiction de la résistance à l'encrassement: sélection des données d'entrée et de sortie, fonctions de transfert possibles, mode d'apprentissage, critères d'arrêt, algorithme d'apprentissage, technique de normalisation, nombre de couches cachées, nombre de nœuds cachés et mesures d'évaluation des performances. Les résultats sont résumés dans le **Tableau III.2.4**.

Tableau III.2.4 : Performances statistiques du modèle RNA

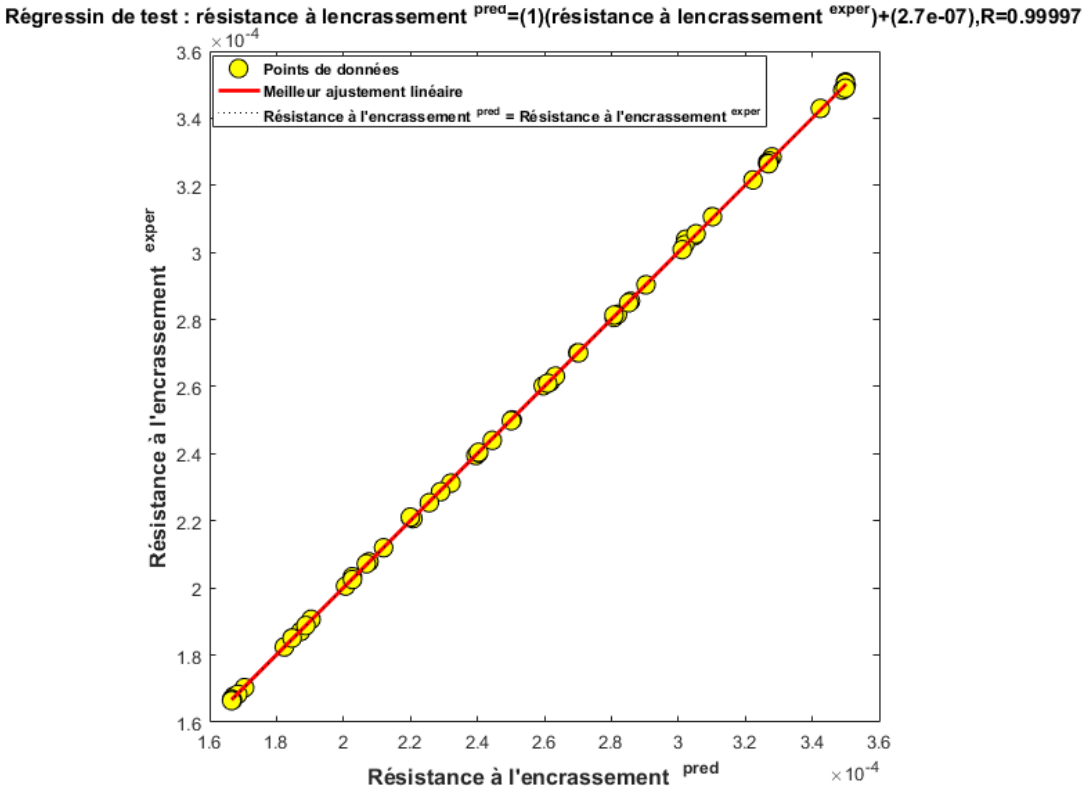
	ERA_{min} (%)	ERA_{max} (%)	ERAM (%)	EQM	REQM	A_f	B_f	K	K'	R^2
Apprentissage	8.3227e-4	0.4781	0.1211	1.3051e-13	3.6127e-7	1	1	1	1	0.99996
Test	2.6989e-5	0.5952	0.1393	2.3354e-13	4.8326e-7	1	1	0.9995	1.0005	0.99993
Validation	0.0055	0.3146	0.1295	1.3386e-13	3.6588e-7	1	1	0.9998	1.0002	0.99996
Global	2.6989e-5	0.5952	0.1238	1.4116e-13	3.7572e-7	1	1	0.9999	1.0001	0.99996

La performance d'un réseau entrainé peut être mesurée dans une certaine mesure par les erreurs sur les ensembles d'apprentissage, test, validation et total, mais il est souvent utile d'étudier la réponse du réseau de manière plus détaillée. Une option qui consiste à effectuer une analyse de régression qui est une mesure de degré de succèsde sortieà expliquer les variations dans la cible. Les valeurs de R obtenues pour la sortie estimée sont 99,998%, 99,997%, 99,998% et 99,998% comme le montre sur la

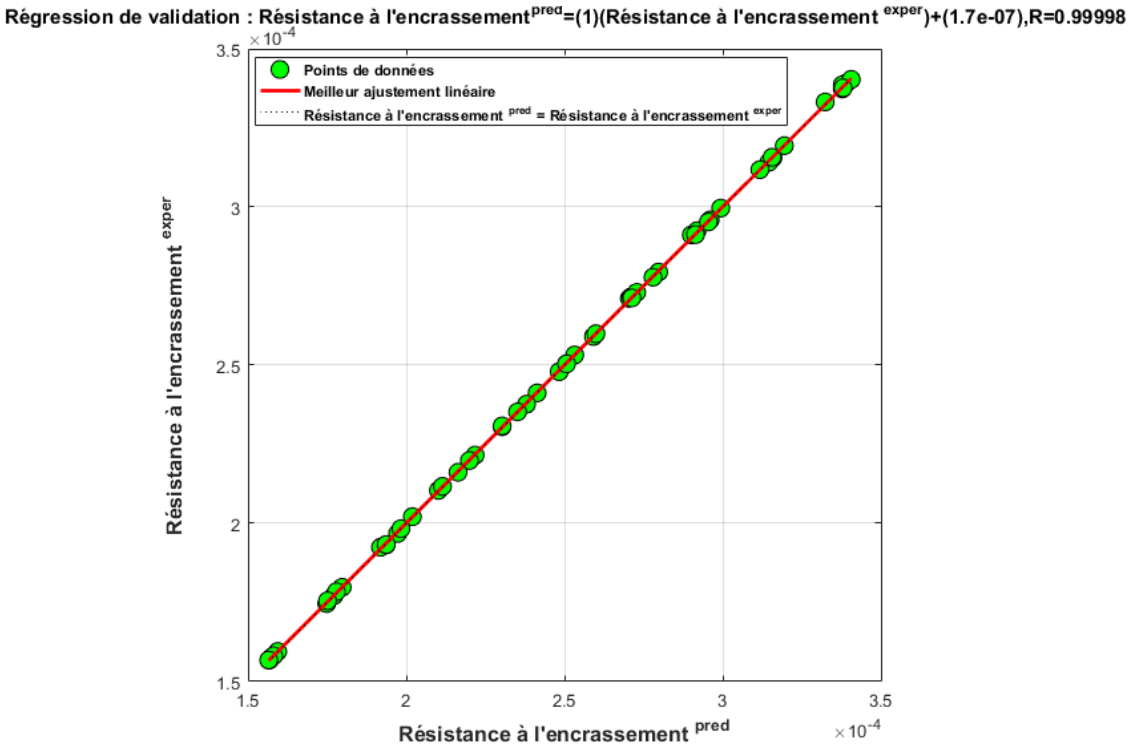
Figure III.2.3. L'ajustement linéaire de la relation sortie-cible est près de la ligne 1÷1 (sortie = cible), qui est un bon signe à un apprentissage précis du réseau.



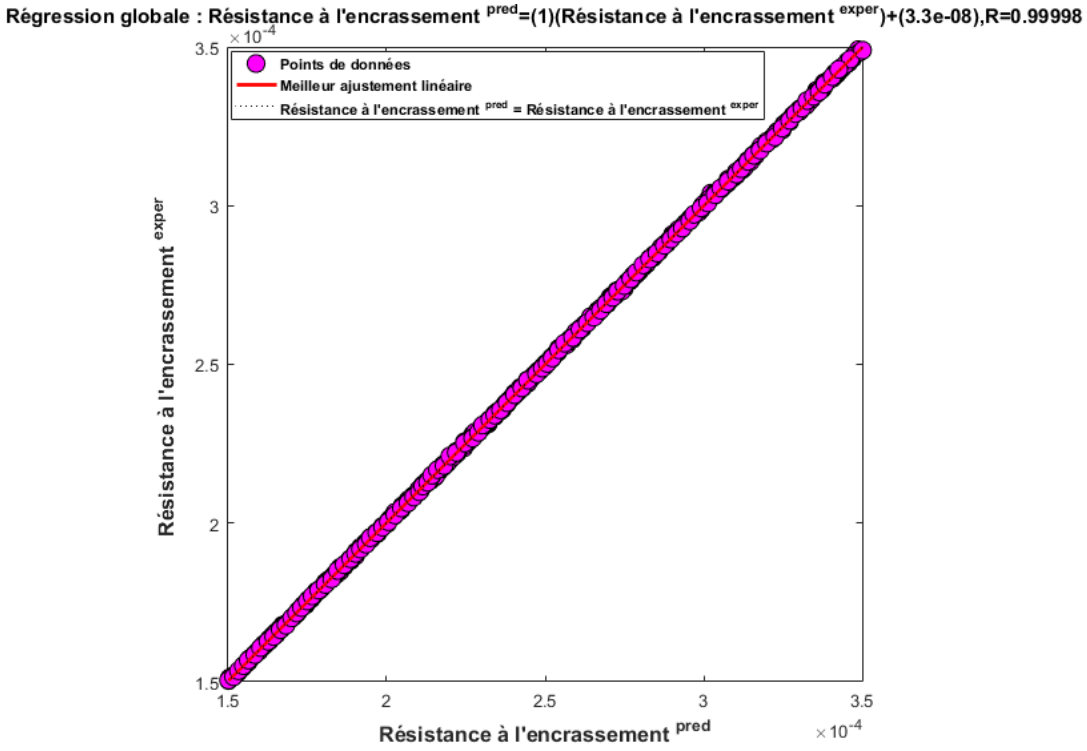
(a)



(b)



(c)



(d)

Figure III.2.3 : Tracé entre la résistance à l'encrassement adimensionnelle expérimentale et la prédiction du RNA pour l'ensemble de données (a) d'apprentissage, l'ensemble de données (b) de test, l'ensemble de données (c) de validation et pour l'ensemble de données (d) globales.

III.2.4. Résultats et discussion

III.2.4.1. Réseau de neurones

La sélection d'un algorithme d'apprentissage appropriée RNA a toujours été une tâche difficile. Son importance est également comme l'architecture du réseau et de la géométrie.

Nous avons effectué des tests expérimentaux approfondies afin de déterminer le meilleur algorithme d'apprentissage, [297]. Au total, quatorze algorithmes d'apprentissage différents pour les algorithmes des réseaux MLP disponibles dans Matlab ont été utilisés.

Une seule couche cachée a été adoptée avec une variation dans le nombre de neurones de 1 à 30 pour chaque algorithme testé. A chaque nouvelle configuration du réseau, trente essais ont été réalisés parce que les réponses des réseaux ne sont pas stables, ce qui signifie que la performance du même réseau est variable d'une séance d'entraînement à l'autre.

La comparaison détaillée de la performance des réseaux de neurones MLP entrainés par les différents algorithmes mentionnés ci-dessus est représentée sur le **Tableau III.2.5**. Dans la présente étude, l'algorithme de *Levenberg-Marquardt* a été considéré comme l'algorithme d'apprentissage car il pourrait avoir une erreur absolue relative maximale (RAE_{max}) plus petite que d'autres algorithmes d'apprentissage.

Tableau III.2.5 : Comparaison de 14 algorithmes de rétro-propagation avec 30 neurones dans la couche cachée

Algorithme de rétropropagation	Fonction	Erreur relative absolue (ERA_{Max}) %	Epoch	Coefficient de détermination (R^2)	Meilleure équation linéaire
RétropropagationLevenberg – Marquardt	**trainlm**	**0.314**	**1000**	**0.99996**	**Y= 1X+1.5e-7**
Rétropropagation de régularisation bayésienne	trainbr	0.317	1000	0.99996	Y= 1X-4.6e-10
Rétropropagation du gradient conjugué Powell-Beale	traincgb	0.354	1000	0.99985	Y= 1X+8.9e-8
Rétropropagation de gradient conjugué Fletcher – Reeves	traincgf	0.989	1000	0.99984	Y= 1X+4.6e-8
Rétropropagation de gradient conjugué Polak – Ribiere	traincgp	1.142	1000	0.99982	Y= 1X+1.9e-7
Rétropropagation de gradient conjugué à l'échelle	trainscg	0.954	1000	0.99987	Y= 1X+1.9e-8
Descente de gradient par lots	traingd	2.840	1000	0.99739	Y= 0.99X+1.4e-6
Descente de gradient avec rétropropagation du taux d'apprentissage adaptatif	traingda	2.604	1000	0.99831	Y= 1X+8.8e-7
Descente de gradient par lots avec élan	traingdm	3.085	1000	0.99684	Y= 0.99X+1.5e-6
Rétropropagation à taux d'apprentissage variable	traingdx	2.589	1000	0.99884	Y= 1X+6.3e-7
Rétropropagation sécante en une étape	trainoss	1.068	1000	0.99982	Y= 1X+1.2e-7
Rétropropagation résiliente	trainrp	0.759	1000	0.99980	Y= 1X+4.7e-8
Rétropropagation quasi-Newton BFGS	trainbfg	0.341	1000	0.99997	Y= 1X-2.5e-10
Formation incrémentale d'ordre aléatoire	trainr	2.001	1000	0.99938	Y= 0.99X+ e-6

Cependant, les performances du modèle RNA ont été mesurées statistiquement par RAE_{max} et R^2 selon **l'Eq. (III.2.9)** et **(III.2.6)** respectivement, qui a été calculée à l'aide des valeurs expérimentales et des prévisions de réseau. Par conséquent, RAE_{max} a été utilisé comme une fonction d'erreur qui mesure les performances du réseau.Le réseau de (RAE_{max} et R^2)maximum a été sélectionnée comme le meilleur modèle RNA.

Pour obtenir le nombre optimal de neurones dans la couche cachée, une série de topologies ont été utilisées, en utilisant l'algorithme de gradient conjugué *Levenberg-Marquardt*mais à l'échelle tel que le nombre de neurones varier de 1 à 30 **Figure III.2.4** pour maximiser RAE_{max} en recherchant un ensemble de poids et biais de connexion qui amènent l'RNA à produire des sorties égales ou proches des valeurs cibles.

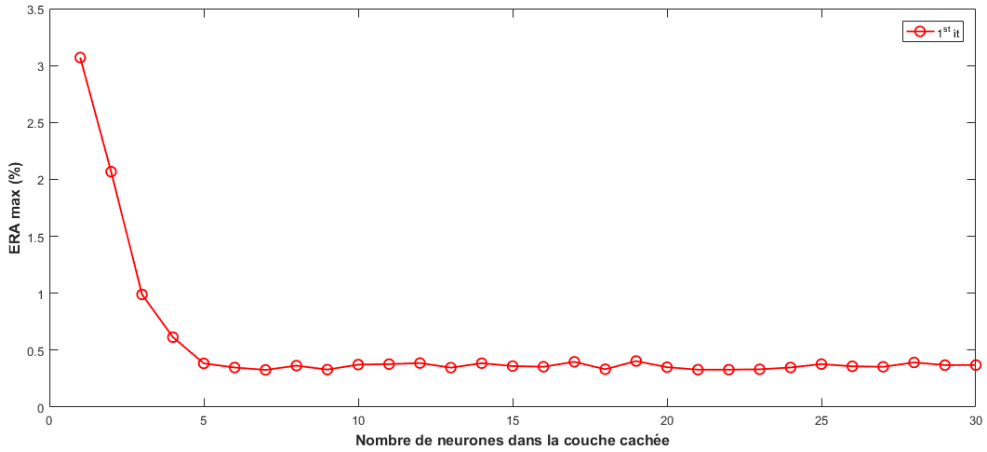


Figure III.2.4 : Effet du nombre de neurones dans la couche cachée sur l'erreur relative absolue du réseau de neurones

Pour approximer les points de données réels, une mesure statistique qui donne la qualité et l'efficacité de l'ajustement de la droite de régression d'un modèle a été vérifiée par R^2. R^2 de 0,99996 signifie que la droite de régression correspond aux données.

Les prévisions des résultats par RNA par rapport aux résultats expérimentaux pour les ensembles de données d'apprentissage, test et de validation sont tracées sur la **Figure III.2.5** pour la résistance à l'encrassement. Les performances des réseaux sélectionnés {7-7-1} sont décrites sur la **Figure III.2.5.** L'RNA était bien formée car R^2 est supérieur à 0,9999 pour le réseau de prévision.

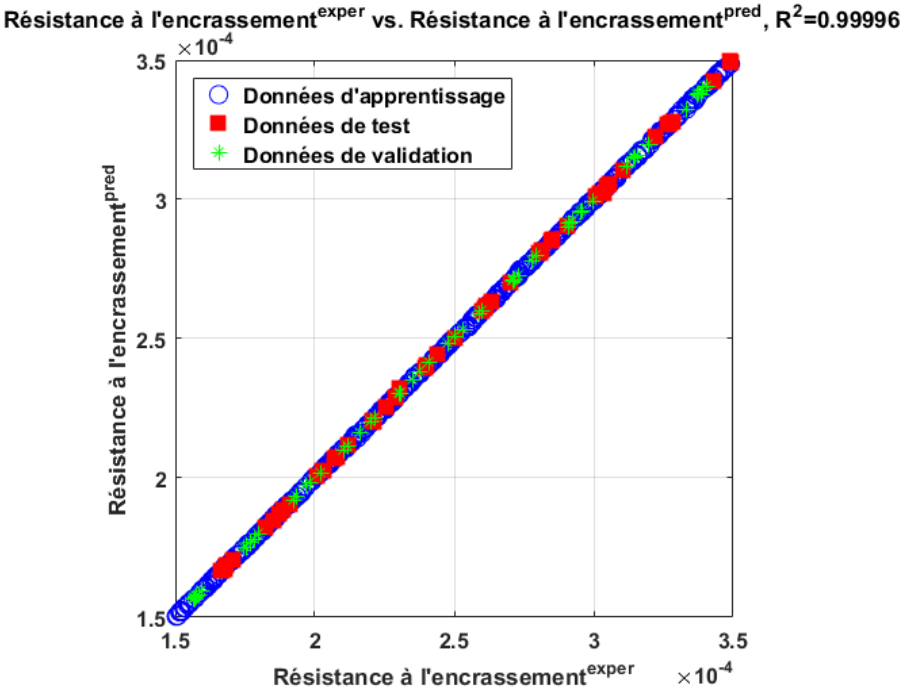


Figure III.2.5 : Tracé entre les données expérimentales et la prédiction du réseau neuronal de la résistance à l'encrassement

III.2.4.2. Analyse de sensibilité

Afin d'étudier les effets des paramètres d'entrée sélectionnés sur les sorties prévues, une étude de sensibilité est effectuée, où le modèle choisi pour étudier a 7 entrées, 1 sortie et 7 neurones dans sa couche cachée, il utilise le min-max méthode comme technique de normalisation et *Levenberg-Marquardt* comme algorithme d'apprentissage. Une fois que le réseau a été formé et optimisé (poids et biais), la matrice de poids sera générée dans le **Tableau III.2.5.**

Afin d'évaluer l'importance relative des variables d'entrée, la matrice des poids a été exploitée dans **l'Eq. (III.2.15)** proposé par D. G. Garson:[274].

$$I_J = \frac{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_0}\right|\right)}{\sum_{k=1}^{k=N_i}\left\{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_0}\right|\right)\right\}} \qquad \text{(III.2.15)}$$

où I_j représente l'importance relative de la $j^{ème}$ variable d'entrée sur la variable de sortie, N_i et N_h sont l'ensemble des neurones d'entrée et cachés, respectivement, w est les poids de connexion, les exposants 'i', 'h' et 'o' se réfèrent aux couches d'entrée, cachée et de sortie, respectivement, et 'k', 'm' et 'n' font référence aux neurones d'entrée, cachés et de sortie, respectivement. Notez que le numérateur de **l'Eq. (III.2.15)** décrit la somme des produits des poids absolus pour chaque entrée. Cependant, le dénominateur dans **l'Eq. (III.2.15)** représente la somme de tous les poids alimentant l'unité cachée, en prenant les valeurs absolues [274]. Un résumé des résultats obtenus est présenté sur la **Figure III.2.6**, où il a été constaté que toutes les variables d'entrée ont un fort effet sur l'estimation de la résistance à l'encrassement.

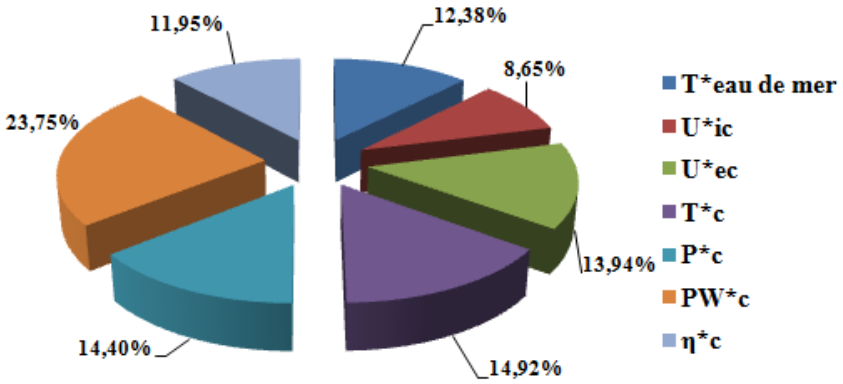


Figure III.2.6 : Importance relative (%) des variables d'entrée sur la valeur de la résistance à l'encrassement calculée

III.2.4.3. Interface graphique pour la résistance à l'encrassement sans dimension

Notre modèle basé sur la formule mathématique non linéaire du réseau de neurones optimisé (RNA) est présenté dans **l'Eq. (III.2.16)** reliant les entrées à la sortie **Tableau III.2.2.**

$$RE^{\star} = \sum_{n=1}^{n}\left[w_{ij(1.n)} \left(\frac{2}{1+\exp\left(-2\left(\left(\sum_{m=1}^{m} w_{i(n.m)} In_{(m)}\right)+b_{i(n)}\right)\right)} - 1 \right)\right] + b_j \qquad \text{(III.2.16)}$$

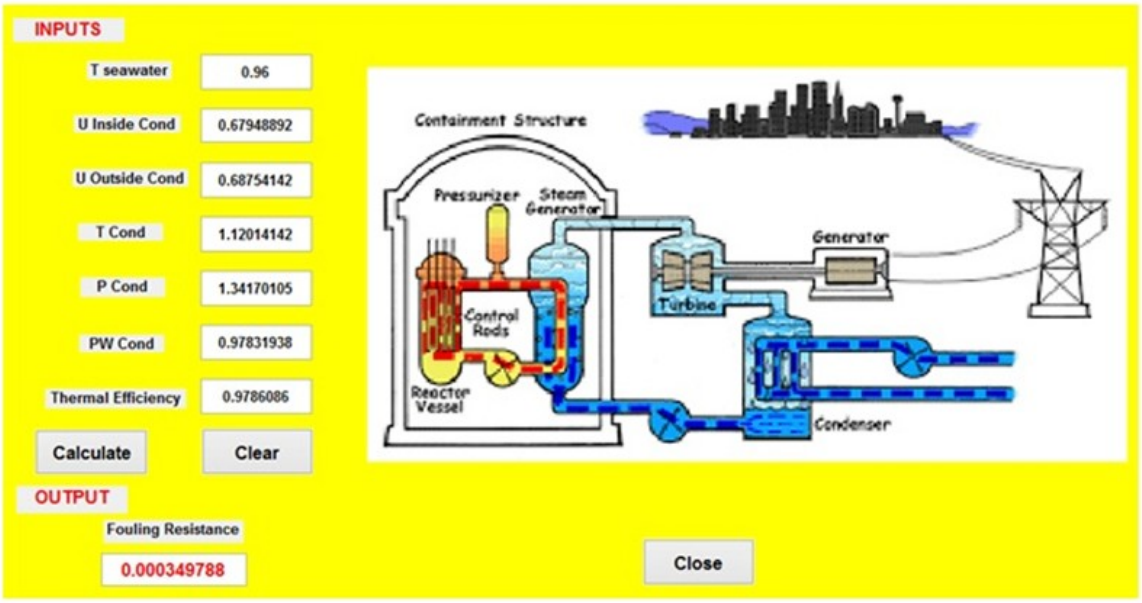


Figure III.2.7 : Interface MATLAB pour une résistance à l'encrassement sans dimension (Tseawater : **Teau de mer** ; U Inside Cond : **U Intérieur du condenseur** ; U Outside Cond : **U Exterieur du condenseur** ; T Cond : **Température du condenseur** ; P Cond : **Pression du condenseur** ; PW Cond : **Puissance du condenseur** ; Thermal Efficiency : **Rendement Thermique**)

Après avoir optimisé le modèle de réseau neurones, un programme informatique a été développé dans MATLAB **Figure III.2.7.** Cela permet à l'utilisateur de disposer de toutes les entrées nécessaires pour faire fonctionner le modèle afin de calculer la résistance à l'encrassement dans le condenseur. L'interface a été conçue pour offrir plus de flexibilité dans l'utilisation du modèle RNA pour un calcul rapide et facile de la résistance à l'encrassement.

III.2.4.4. Performances optimales au moyen d'RNAi

Selon le modèle RNA, une méthode d'estimation des paramètres d'entrée a été développée qui influence la résistance à l'encrassement lorsque les paramètres d'entrée sont bien connus, [284, 298, 299].

Le **Tableau III.2.6** donne les paramètres obtenus (w_i, w_{ij}, b_i et b_j) du meilleur ajustement pour sept neurones dans la couche cachée. Ces paramètres sont utilisés dans le modèle proposé pour simuler la valeur RE⋆.

Tableau III.2.6 : Paramètres statistiques obtenus pour le modèle RNA

nombre de neurones	W_1							Bais	W_2	Bais
	T^*eau de mer	U^*ic	U^*oc	T^*c	P^*c	PW^*c	η^*c	1	RE^*	2
1	0.500326	-0.969916	1.198230	0.712472	-2.217929	-0.598790	-0.462936	-1.072256	-0.386981	0.22485
2	-0.459379	0.476224	1.087681	0.718236	0.505942	1.242267	-0.362146	-2.384026	-0.138044	
3	-1.096048	1.655369	-1.384254	-0.949099	-0.624925	0.343710	-0.243276	0.895478	-1.982093	
4	1.537030	-4.655751	2.070056	0.953992	0.937874	0.074150	1.044117	0.176574	-1.911302	
5	0.007095	2.364086	0.371170	0.270999	0.265573	-0.15699	-0.302598	-0.324478	-0.613290	
6	0.551937	-0.085535	0.465512	0.321671	-0.687249	-0.163053	0.021205	0.793517	-0.960898	
7	0.204665	-1.372054	0.482392	0.34565	-0.615597	-0.187586	-0.149514	0.868911	1.084011	

W_1:matrice de poids entre les couches d'entrée et cachées.
W_2:matrice de poids entre les couches cachées et de sortie.

Un réseau général **Eq. (III.2.4)** est constitué par la fonction de transfert (tansig et purelin). Ensuite, la sortie est donnée en fonction des entrées **Eq. (III.2.17)**, où n est le nombre de neurones dans la couche cachée (n = 7), m est le numéro de l'entrée (m = 7), w est le poids et b est le biais.

L'Eq. (III.2.17) peut être exprimée comme:

$$RE^{\star} = b_j - \sum_n w_{ij(1.n)} + \sum_s \left[\frac{2w_{ij(i.n)}}{1+\exp\left(-2\left(\left(\sum_m w_{i(n.m)} In_{(m)}\right) + b_{i(n)}\right)\right)} \right] \qquad \text{(III.2.17)}$$

À cette étape, la fonction a été obtenue qui doit être minimisée à zéro pour obtenir des paramètres d'entrée optimaux (n) In (m = x):

$$Fun\left(In_{(m)}\right) = b_j - \sum_n w_{ij(i.n)} + \sum_n \left[\frac{2w_{ij(i.n)}}{1+\exp\left(-2\left(w_{i(n.m)} In_{(x)} + \sum_{m\neq x} w_{i(n.m)} In_{(m)} + b_{i(n)}\right)\right)} \right] \qquad \text{(III.2.18)}$$

Où x sont les différentes valeurs de la température de l'eau de mer de refroidissement du condenseur sans dimension à calculer. Le modèle RNA proposé avait sept neurones dans la couche cachée. Il était donc essentiel d'appliquer une méthode d'optimisation, [300,301].

Le paramètre d'entrée optimisé a été établi à l'aide des algorithmes simplex de Nelder-Mead dans les différentes conditions pour prouver la faisabilité de l'utilisation d'RNAi. Un test a été effectué avec différentes données pour optimiser l'une des entrées - par exemple différentes valeurs de température de l'eau de mer de refroidissement du condenseur sans dimension (T* eau de mer) d'une part et d'autre part les paramètres simulés ont été comparés aux données expérimentales afin de vérifier l'exactitude de RNAi au moyen de l'erreur donnée dans **l'Eq. (III.2.19).**

$$\text{Error} = \frac{|\text{Exp} - \text{Sim}|}{\text{Exp}} \times 100 \qquad \text{(III.2.19)}$$

Cas 1. Un groupe de paramètres a été fourni pour le processus de résistance à l'encrassement prévu avec k = 1, n = 7 et m = 7. La valeur d'entrée (par exemple T * eau de mer) peut être calculée par RNAi. Les conditions expérimentales pour ce test, pour une valeur de sortie requise RE* = 0,00015, avec des valeurs d'entrée: U*ic = 0,855440, U*ec = 0,860584, T*c = 1,07401318, P*c = 1,161460, PW*c = 0,991597, η*c = 0.991542, en minimisant la fonction non linéaire donnée dans **l'Eq. (III.2.20).**

$$F = -A + \frac{2w_{ij(1.1)}}{1+\exp\left(x_1 + 2w_{i(1.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.2)}}{1+\exp\left(x_2 + 2w_{i(2.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.3)}}{1+\exp\left(x_3 + 2w_{i(3.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.4)}}{1+\exp\left(x_4 + 2w_{i(4.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.5)}}{1+\exp\left(x_5 + 2w_{i(5.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.6)}}{1+\exp\left(x_6 + 2w_{i(6.7)}T^*\text{seawater}\right)} + \frac{2w_{ij(1.7)}}{1+\exp\left(x_7 + 2w_{i(7.7)}T^*\text{seawater}\right)}$$

(III.2.20)

Où

$$A = FR^* - b_j + w_{ij(1.1)} + w_{ij(1.2)} + w_{ij(1.3)} + w_{ij(1.4)} + w_{ij(1.5)} + w_{ij(1.6)} + w_{ij(1.7)} \qquad \text{(III.2.21)}$$

$$x_1 = -2\left(w_{i(1.2)}v_2 + w_{i(1.3)}v_3 + w_{i(1.4)}v_4 + w_{i(1.5)}v_5 + w_{i(1.6)}v_6 + w_{i(1.7)}v_7 + b_1\right) \qquad \text{(III.2.22)}$$

$$x_2 = -2\left(w_{i(2.2)}v_2 + w_{i(2.3)}v_3 + w_{i(2.4)}v_4 + w_{i(2.5)}v_5 + w_{i(2.6)}v_6 + w_{i(2.7)}v_7 + b_2\right) \qquad \text{(III.2.23)}$$

$$x_3 = -2\left(w_{i(3.2)}v_2 + w_{i(3.3)}v_3 + w_{i(3.4)}v_4 + w_{i(3.5)}v_5 + w_{i(3.6)}v_6 + w_{i(3.7)}v_7 + b_3\right) \qquad \text{(III.2.24)}$$

$$x_4 = -2\left(w_{i(4.2)}v_2 + w_{i(4.3)}v_3 + w_{i(4.4)}v_4 + w_{i(4.5)}v_5 + w_{i(4.6)}v_6 + w_{i(4.7)}v_7 + b_4\right) \qquad \text{(III.2.25)}$$

$$x_5 = -2\left(w_{i(5.2)}v_2 + w_{i(5.3)}v_3 + w_{i(5.4)}v_4 + w_{i(5.5)}v_5 + w_{i(5.6)}v_6 + w_{i(5.7)}v_7 + b_5\right) \qquad \text{(III.2.26)}$$

$$x_6 = -2\left(w_{i(6.2)}v_2 + w_{i(6.3)}v_3 + w_{i(6.4)}v_4 + w_{i(6.5)}v_5 + w_{i(6.6)}v_6 + w_{i(6.7)}v_7 + b_6\right) \qquad \text{(III.2.27)}$$

$$x_7 = -2\left(w_{i(7.2)}v_2 + w_{i(7.3)}v_3 + w_{i(7.4)}v_4 + w_{i(7.5)}v_5 + w_{i(7.6)}v_6 + w_{i(7.7)}v_7 + b_7\right) \qquad \text{(III.2.28)}$$

V_1:Différentes valeurs de température de l'eau de mer de refroidissement du condenseur sans dimension;

V_2: Coefficient de transfert de chaleur sans dimension global à l'intérieur du condenseur;
V_3: Coefficient de transfert de chaleur sans dimension à l'extérieur du condenseur;
V_4: Température du condenseur sans dimension;
V_5: Pression du condenseur sans dimension;
V_6: Puissance de sortie du condenseur sans dimension;
V_7: Efficacité thermique globale du condenseur sans dimension.

Avec des poids et des biais, la température de l'eau de mer du procédé peut être calculée pour la sortie requise, en utilisant le logiciel MATLAB avec l'optimisation Toolbox, [298]. La valeur de résultat (T*eau de mer) simulée par RNAi était de 0,6. De plus, en utilisant **l'Eq. (III.2.19)** la valeur calculée a une erreur de 0% par rapport au résultat expérimental **Tableau III.2.7.**

Tableau III.2.7 : Erreur entre les entrées expérimentales et calculée par RNAi

RNAi Entrées	Expérimentale	Calculée	Erreur % $\text{Erreur} = \frac{\lvert \text{exp} - \text{sim} \rvert}{\text{exp}} \times 100$
	exp	cal	
Entrée 1 ⟶ Sortie 1	0.6	0.6	0
Entrée 2 ⟶ Sortie 2	0.8554	0.8528	0.3
Entrée 3 ⟶ Sortie 3	0.8605	0.8605	0
Entrée 4 ⟶ Sortie 4	1.0740	1.0740	0
Entrée 5 ⟶ Sortie 5	1.1615	1.1615	0
Entrée 6 ⟶ Sortie 6	0.9916	0.9908	0.07
Entrée 7 ⟶ Sortie 7	0.9915	0.9985	0.3

III.2.5. Comparaison avec d'autres modèles

Pour évaluer l'importance des résultats obtenus, nous avons essayé de les comparer avec des études similaires, et surtout, avec les modèles qui ont les mêmes ou la plupart des intrants tels que ceux que nous avons utilisés. Nous constatons que dans la plupart des modèles, l'objectif est de prédire l'encrassement dans les échangeurs de chaleur comme Jradi, R et al. [286] une étude comparative basée sur certains indices statistiques a été réalisée entre trois modèles différents en ce qui concerne la modélisation et la prédiction des pertes de chaleur, performances des échangeurs dues au phénomène d'encrassement. Les entrées du modèle RNA utilisé pour les trois types d'échangeurs sont les températures d'entrée et de sortie, la température de la vapeur, le débit volumique, la densité et le temps pour estimer la résistance à l'encrassement. Un modèle RNA développé par Davoudi, E et Vaferi, B. [259] pour l'estimation du degré d'encrassement, les entrées du réseau sont la densité, la température de surface, la température du fluide, le diamètre du passage du fluide, la vitesse du fluide, la

concentration d'oxygène dissous dans fluide et le temps. Kashani, M.N et al. [302] ont développé un modèle RNA pour estimer la surveillance en ligne et la prédiction du comportement d'encrassement du pétrole brut pour les échangeurs de chaleur industriels à tube et enveloppe. Les données d'entrée du réseau sont le débit de pétrole brut côté tube, la température d'entrée côté tube et la température d'entrée côté enveloppe. Aminian, J et Shahhosseini, S. [303] un modèle de réseau neurones artificielRNA a été utilisé pour développer un ensemble de formulations mathématiques pour identifier les régions où il y a moins / pas d'encrassement pour les échangeurs de préchauffage d'un pétrole brut en utilisant des variables d'entrée comme le nombre de Reynolds Re, le nombre de Prandtl Pr et la température de surface. Les résultats obtenus à partir de ces modèles que nous avons mentionnés et nos résultats sont rassemblés dans le **Tableau III.2.8.**

Tableau III.2.8 : Résultats de notre modèle par rapport à divers modèles similaires

Nom du modèle	Encrassement dans les échangeurs de chaleur										
	RAE_{min} (%)	RAE_{max} (%)	MAPE (%)	MSE	RMSE	A_f	B_f	K	K'	R	R^2
Notre modèle	0.0055	0.3146	0.1295	1.338e-13	3.6588e-7	1	1	0.9998	1.0002	0.9999	0.99996
R. Jradiet al:											
-Echangeur de chaleur tubulaire en acier inoxydable	–	–	0.065	2.168e-11	4.656e-6	–	–	–	–	0.994	–
-Blocs de graphite échangeur de chaleur (A)	–	–	0.048	1.811e-11	4.2561e-6	–	–	–	–	0.995	–
-Blocs de graphite échangeur de chaleur (B)	–	–	0.046	6.577e-11	8.110e-6	–	–	–	–	0.993	–
E. Davoudi and B.Vaferi	–	–	5.42	0.0013	0.0355	–	–	–	–	–	0.97781
M. N. Kashani et al.	–	8	–	–	–	–	–	–	–	–	–
I. Aminian and S. Shahhosseini	–	–	15.83	–	–	–	–	–	–	–	–

III.II.6. Conclusion

Dans cette contribution, une méthodologie pour choisir le modèle RNA pour prédire la résistance à l'encrassement du condenseur. L'objectif de cette contribution était de sélectionner le meilleur modèle. La méthodologie commence par une recherche approfondie afin de sélectionner un modèle avec une complexité minimale et des performances optimales.

La méthode de modélisation RNA présente de nombreux avantages, tels que la rapidité, l'adaptabilité, la généralisation et la simplicité, ce qui en fait un choix

intéressant pour la modélisation de systèmes complexes non linéaires (encrassement des échangeurs-condenseurs).

Au cours du processus d'apprentissage, nous avons utilisé plusieurs configurations de réseaux de neurones. Nous avons commencé avec l'utilisation de 14 algorithmes d'entraînement, en observant l'effet de chacun d'eux sur les performances du réseau, nous avons donc choisi les trois premiers d'entre eux (*trainlm, trainbr, trainbfg*) et nous avons tenté d'améliorer leurs performances en utilisant une technique de normalisation. Parmi les trois réseaux obtenus, nous avons sélectionné le meilleur réseau de prédiction, qui a également été testé avec une couche cachée et plusieurs nœuds cachés. Il a été constaté qu'une couche cachée avec 7 neurones peut fournir une meilleure prédiction.

Notre modèle a été développé par une architecture de rétropropagation MLP avec action directe avec l'algorithme de formation *Levenberg-Marquardt*. En fait, les résultats confirment que les réseaux de neurones MLP sont suffisamment compétents pour prédire la résistance à l'encrassement lors de l'utilisation des conditions de fonctionnement de l'échangeur de chaleur-condenseur comme entrées.

Nous avons observé que le réseau avec une couche cachée de {7-7-1} donne un coefficient de corrélation supérieur à 0,9999 avec une petite erreur ($EQMR = 3{,}6588 \times 10^{-07}$) pour l'ensemble de la base de données ce qui signifie que le réseau de neurones était bien formé. L'RNA est un outil d'interpolation adéquat pour le comportement non linéaire de $RE^{\star}$ pour toutes les conditions de fonctionnement mentionnées ci-dessus, dans lesquelles une excellente prédiction a été obtenue. Sur la base de l'analyse de sensibilité, nous avons constaté que toutes les variables d'entrée avaient un effet significatif sur l'estimation de la résistance à l'encrassement. De plus, sur la base du modèle, une méthodologie a été développée pour estimer les conditions de fonctionnement optimales à partir d'RNAi lorsqu'il est nécessaire d'obtenir un résultat optimal pour les entrées connues avec la résistance à l'encrassement requise $RE^{\star}$, en appliquant la méthode d'optimisation simplex de Nelder-Mead. Néanmoins, le calcul mathématique de l'RNAi a été effectué dans le cas 1.

Toutes les entrées RNA ont été estimées en utilisant RNAi avec un écart relatif moyen qui ne dépasse pas 0,095%. En comparant ces résultats à d'autres recherches

dans le même contexte, nous pouvons dire que notre modèle donne de meilleures performances à de nombreux autres modèles.

Contribution 3 :
Une Application du réseau de neurones artificiel (RNA-MLP) pour la prédiction de la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides MgO-eau et CuO-eau

III.3.1. Introduction

L'encrassement de surface réduit les performances de divers types d'équipements de traitement tels que les échangeurs de chaleur, la contamination des réacteurs nucléaires ou le blocage des filtres à membrane, des unités d'osmose inverse qui sont utilisés dans le dessalement, la production d'électricité et les usines de traitement des eaux et des eaux usées. La lutte contre l'encrassement des équipements de traitement coûte aux industries des milliards de dollars chaque année et peut rendre certains procédés non rentables qui sont par ailleurs viables sur le plan technologique et environnemental. L'encrassement particulaire a également fait l'objet de nombreuses recherches et divers modèles ont été proposés pour prédire l'étendue de l'encrassement particulaire dans les équipements de traitement.

Pour augmenter le taux de transfert de chaleur, des ailettes sont introduites. Les performances de l'échangeur de chaleur peuvent être évaluées en utilisant une corrélation de transfert de chaleur par convection empirique basée sur les moindres carrés qui ne peut s'appliquer que pour les conditions d'écoulement et les différences de température moyennes logarithmiques. Le mode numérique utilise également les performances d'un échangeur de chaleur en utilisant la dynamique des fluides computationnelle (ANSYS-FLUENT). Un réseau de neurones artificiels (RNA) est une boîte à outils utilisée à des fins de modélisation et de validation. Un nano-fluide est un fluide contenant des particules de taille nanométrique, appelées nanoparticules. Ces liquides sont conçus des suspensions colloïdales de nanoparticules dans un liquide de base. Les nanoparticules utilisées dans les nano-fluides sont généralement constituées de métaux, d'oxydes, de carbures ou de nanotubes de carbone. Les liquides de base normaux contiennent de l'eau, de l'éthylène glycol et de l'huile. G. Jamuna Rani, [304].

Dans la littérature, les articles publiés sont rares pour identifier le phénomène d'encrassement et ses impacts, à savoir une étude complète présentée dans une revue de littérature concernant l'atténuation et le retard de l'encrassement et du dépôt de particules dans l'échangeur de chaleur présentée dans de récentes études expérimentales et numériques étudiées par divers chercheurs, [305]. Williamson, R. et al. Ont étudié le dépôt de particules d'hématite ($\alpha - Fe_2O_3$) en suspension dans l'eau et constaté que le dépôt dépend du pH de la suspension, [306]. Grandgeorge, S. et coll. ont réalisé une étude expérimentale sur l'encrassement particulaire en phase liquide ont

utilisé de l'eau d'ionisée contenant des particules de TiO_2 comme fluide d'encrassement dans les échangeurs de chaleur à plaques ondulées en acier inoxydable [307]. Peyghambarzadeh, S. M. et al. Ont étudié le dépôt de particules d'alumine α de l'ordre du micron introduit dans un fluide à base d'hydrocarbure (n-heptane). Le dépôt lors du transfert de chaleur par convection forcée est mesuré à l'aide d'une approche thermique précise. De plus, un nouveau modèle théorique a été développé pour prédire la résistance asymptotique à l'encrassement, [308]. Une étude expérimentale pour examiner le rôle de la génération de bulles sur l'encrassement par transfert de chaleur dans un échangeur de chaleur annulaire, une comparaison systématique est effectuée pour étudier l'effet de la génération de bulles dans le régime d'ébullition sous-refroidi sur la cristallisation et l'encrassement particulaire, [309]. Nikkhah, V. et coll. Ont réalisé une étude expérimentale d'un anneau vertical conventionnel sur le paramètre de résistance à l'encrassement et le coefficient de transfert de chaleur de CuO / eau et d'extraire une nouvelle corrélation pour estimer la résistance à l'encrassement des nanoparticules basée sur la condition de diffusion isotherme est proposée, [310]. Tang, K. H. et coll. ont étudié le dépôt de carbonate de calcium artificiellement durci dans un échangeur de chaleur à double tube et simulé un cas réel de processus opérationnel de l'usine lié à l'équipement de l'échangeur de chaleur, [311]. Wang, S. et coll. Ont appliqué une expérience et étudié les effets de l'encrassement particulaire sur le transfert de chaleur sous une suspension de particules de magnésie bouillante à écoulement sous-refroidi dont les tailles de particules sont de 40 nm et 10 µm. En changeant la concentration, le flux thermique, le débit massique et la température d'entrée des suspensions, les caractéristiques de l'encrassement des particules de magnésie ont été trouvées. Ensuite, la différence entre nano et microparticule est observée et discutée, [312]. Une étude expérimentale a été réalisée sur les caractéristiques d'encrassement de la suspension γ-Al_2O_3 / eau sur une surface en acier inoxydable en modifiant le flux thermique et la température d'entrée dans des conditions d'ébullition à écoulement monophasé et sous écoulement refroidi avec analyse du mécanisme par un spectrophotomètre visible, [313]. Sarafraz, M. M. et coll. ont étudié expérimentalement l'influence de différents paramètres de fonctionnement tels que les concentrations diluées de nano-fluide (en poids), le flux thermique et le flux massique sur la résistance à l'ébullition monophasée, à deux phases et à l'encrassement particulaire du nano-fluide

CuO/EG. On montre que les résistances à l'encrassement représentent le comportement linéaire / asymptotique avec le temps en force des régions de transfert de chaleur à ébullition convective et nucléée, [314].

L'objectif de cette contribution est de développer un modèle RNA-MLP pour prédire la résistance à l'encrassement des nano-fluides (MgO-eau et CuO-eau) à partir de données expérimentales de l'échangeur de chaleur en fonction du temps, de la concentration volumétrique, du flux thermique, du débit massique et de la température d'entrée du fluide. La détermination de l'effet de chacun des paramètres d'entrée de la résistance à l'encrassement, en particulier l'effet des différentes concentrations de particules d'une part. Et d'autre part, c'est la plus haute précision du modèle RNA-MLP développé par rapport aux corrélations proposées pour la prédiction de la résistance à l'encrassement.

III.3.2. Modèle de réseaux de neurones artificiels

Le réseau de neurones artificiels est une nouvelle approche pour la simulation de systèmes linéaires et non linéaires de grande complexité dans divers domaines de la science et de l'ingénierie. Un réseau de neurones artificiels se compose d'un grand nombre d'éléments de traitement appelés neurones. Ils sont reliés par des liens de connexion appelés poids. Pour la conception d'un réseau de neurones artificiels efficace: une couche d'entrée, une couche de sortie, une couche cachée, nombre de neurones dans la couche cachée, fonction de transfert, nombre de couches cachées et algorithme d'apprentissage. Les performances du réseau sont déterminées par la valeur des poids et des biais dans chaque neurone. Le réseau doit être formé à l'aide d'ensembles de données mesurées pour donner la sortie souhaitée à l'aide d'ensembles de données d'entrée, [315, 316].

L'architecture RNA basée sur MLP est illustrée à la **Figure III.3.1.** MLP est une interconnexion de perceptrons dans laquelle les données et les calculs circulent dans une seule direction, des données d'entrée aux sorties. Le nombre de couches dans un RNA est le nombre de couches de perceptrons. La sortie d'un neurone donné est calculée en appliquant une fonction de transfert à une sommation pondérée de son entrée pour donner une sortie, qui peut servir d'entrée à d'autres neurones, [256].

La structure MLP se compose de trois couches: les couches d'entrée, cachées et de sortie. Ils sont créés par de nombreux neurones interconnectés. Chaque couche est

constituée d'une matrice de poids, de neurones artificiels et d'un vecteur de sortie que les biais s'appliquent à chaque neurone, [317].

Cette contribution vise à construire un modèle RNA-MLP, capable de prédire la résistance à l'encrassement dans l'échangeur de chaleur aux nano-fluides en fonction du temps, de la concentration volumétrique, du flux thermique, du débit massique et de la température d'entrée (Temps: t, Concentration volumétrique: C, Flux de chaleur: q, Débit massique: G, Température: T, Conductivité thermique: λ). Le **Tableau III.3.1** montre la gamme des variables.

Tableau III.3.1 : Gamme des variables

Paramètre			Unité	Min	Max
Temps	t		[h]	0,120	26,189
Concentration volumétrique %	C		---	0,1	0,4
Flux de chaleur	q		[KW.m^{-2}]	23,6	800
Débit massique	G		[Kg.m^{-2}.s^{-1}]	40	80
Température	T		[°C]	33	84
Conductivité thermique	λ		[W.m^{-1}.K^{-1}]	18	60
Résistance à l'encrassement	FR		[m^2 K.KW^{-1}]	0,0168	1,9794

Les données d'entrée et de sortie ont été normalisées dans la plage de [y_{min} = -1, y_{max}= 1] en utilisant un algorithme mapminmax donné par **l'Eq. III.III.1.** qui effectue une normalisation de la valeur maximale et minimale de chaque ligne, [290].

$$y = \text{map}\min\max(x) = \frac{(y_{max} - y_{min})(x - x_{min})}{(x_{max} - x_{min})} + y_{min} \qquad \text{(III.2.1)}$$

Après avoir examiné un nombre considérable de réseaux de neurones à structures différentes, l'optimisation des paramètres RNA est effectuée en minimisant l'erreurabsolue moyenneen pourcentage(MAPE), les RNA adéquats sélectionnés dans cet article ont une seule couche cachée avec 30 neurones et une couche de sortie avec un neurone. La couche cachée a une fonction de transfert tangente sigmoïde (code Matlab: tansig). La couche de sortie a une fonction de transfert linéaire (code Matlab: purelin). La structure typique de l'RNA est illustrée à la **Figure III.2.1.**

La formule mathématique qui relie les entrées à la sortie du réseau neuronal optimisé (RNA) est donnée dans **l'Eq. III.2.2**

$$\text{Sortie} = RE = \sum_{n=1}^{n}\left[w_{ij(1.n)}\left(\frac{2}{1+\exp\left(-2\left(\left(\sum_{m=1}^{m} w_{i(n.m)} In_{(m)}\right) + b_{i(n)}\right)\right)} - 1\right)\right] + b_j \qquad \text{(III.2.2)}$$

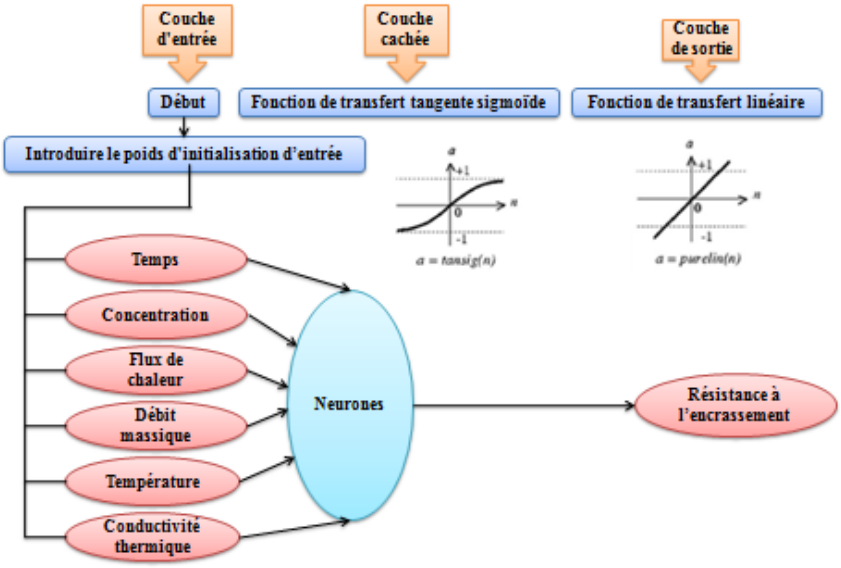


Figure III.3.1: Architecture du modèle RNA-MLP proposé pour prédire le RE

III.3.3. Paramètres d'entrée et erreurs du modèle

Afin de prédire les propriétés physiques avec un réseau de neurone de type RNA-MLP à l'aide de résultats expérimentaux, 375 données sur la résistance à l'encrassement sont divisées en trois sections de données d'entraînement (300 données), de test (37 données) et de validation (38 données). Les sous-ensembles de l'apprentissage, de test et de validation de l'RNA-MLP sont obtenus en sélectionnant 80% de l'ensemble de données comme apprentissage, 10% de l'ensemble de données comme test et 10% de l'ensemble de données comme sous-ensembles de validation.

Les données de test et de validation permettent d'évaluer la structure du réseau de neurone de type RNA-MLP. Test et validation du modèle, construit avec des données indépendante de celles d'entraînement. Obtenir des relations polynomiales appropriées pour les propriétés thermophysiques des nano-fluides MgO-eau et CuO-eau concernant les données d'entrée. Trois critères sont utilisés pour l'évaluation par simulation et la comparaison entre les résultats du modèle et les données expérimentales. Ces critères sont: l'erreur quadratique moyenne (EQM), l'erreur absolue moyenneen pourcentage(ERAM) et le coefficient de détermination (R^2) qui peuvent être calculés comme suit:

$$EQM = \frac{1}{N}\sum_{i=1}^{N}(y^{exp} - y^{cal})^2 \qquad \text{(III.3.3)}$$

$$ERAM(\%) = \frac{100}{N}\sum_{1}^{N}\frac{\left|y^{exp} - y^{cal}\right|}{y^{exp}} \quad \text{(III.3.4)}$$

$$R^2 = 1 - \frac{\sum_{1}^{N}\left(y_i^{exp} - y_i^{cal}\right)^2}{\sum_{1}^{N}\left(y_i^{exp} - \overline{y_i^{exp}}\right)^2} \quad \text{(III.3.5)}$$

T. Ross a proposé deux indices différents pour la détermination de la performance du modèle. Le facteur de biais B_f **(Eq. (III.3.11))**quiest une mesure de la concordance globale entre les valeurs prédites et observées. Il indiquera si et dans quelle mesure les prévisions sont au-dessus ou en dessous de la ligne d'équivalence. Un accord parfait entre les valeurs observées et prédites donnerait un $B_f = 1$. ($B_f = 0.9$ - 1.05 signifie un bon modèle), [296].

La valeur du facteur de précision A_f **(Eq. (III.3.12))** sera toujours égale ou supérieure à un, car toutes les variances sont positives.

$$B_f = 10^{\left(\frac{\sum_{i=1}^{n}\log\frac{y_i^{cal}}{y_i^{exp}}}{n}\right)} \quad \text{(III.3.6)}$$

$$A_f = 10^{\left(\frac{\sum_{i=1}^{n}\left|\log\frac{y_i^{cal}}{y_i^{exp}}\right|}{n}\right)} \quad \text{(III.3.7)}$$

De plus, pour assurer une plus grande validité des modèles développés. Nous avons utilisé certains critères statistiques comme:

$$K = \frac{\sum y_i^{cal} y_i^{exp}}{\sum\left(y_i^{cal}\right)^2} \quad \text{(III.3.8)}$$

$$K' = \frac{\sum y_i^{cal} y_i^{exp}}{\sum\left(y_i^{exp}\right)^2} \quad \text{(III.3.9)}$$

Où: $0.85 \leq K \leq 1.15$; $0.85 \leq K' \leq 1.15$ comme critère d'acceptabilité.

y_i représente le $i^{ème}$ test entraîné ou la valeur de sortie de validation, et y_i^t représente la valeur cible correspondante, n étant le nombre de vecteurs d'entrée.

III.3.4. Résultats et discussion

Dans cette contribution, la performance de RNA avec un nombre variable de neurones (1-30) dans la couche cachée a été étudiée où chaque architecture RNA-MLP a été formée 15 fois afin d'éviter les effets aléatoires. Les résultats ont démontré que les architectures avec une couche cachée pouvaient atteindre l'objectif en termes d'erreurs et de coefficient de détermination. Le **Tableau III.3.2** montre le résultat de la performance statistique du modèle RNA. La précision des réseaux a été évaluée pour chaque époque dans le cadre de la formation (EQM). La meilleure performance de validation est de 10^{-4} à l'époque 1000 (itérations) pour la meilleure topologie de réseau avec ERAM global de 2,4535%, % REQM de 2,54%, les valeurs du facteur de biais $B_f = 1$ et du facteur de précision $A_f = 1$, ce qui indique que le modèle est valide dans la prédiction de RE. Les valeurs de K et K 'indiquent que le modèle est acceptable, [318].

Tableau III.3.2 : Performances statistiques du modèle RNA

	ERAM (%)	EQM	REQM	A_f	B_f	K	K'	R^2
Apprentissage	2.4054	6.5377e-04	0.0256	1	1	0.9991	0.9999	0.99756
Test	1.8922	3.9629e-04	0.0199	1	1	0.9995	0.9993	0.99835
Validation	2.5700	5.8303e-04	0.0241	1	1	0.9982	1.0010	0.99812
Global	2.3714	6.2119e-04	0.0249	1	1	0.9990	1	0.99770

La **Figure III.3.2** montre une comparaison entre les valeurs expérimentales et prévues de la résistance à l'encrassement pendant la phase d'apprentissage, de test et de validation. Il existe une très bonne concordance entre les données cibles et les résultats obtenus à partir du modèle RNA-MLP. La valeur R^2 pour la résistance à l'encrassement est supérieure à 0,99 pour les ensembles de données d'apprentissage, de validation et de test montrant que le modèle a capturé les caractéristiques de manière assez précise. Les résultats confirment la grande capacité du modèle RNA-MLP utilisé et démontrent un bon ajustement entre les valeurs prédites et expérimentales de la résistance à l'encrassement.

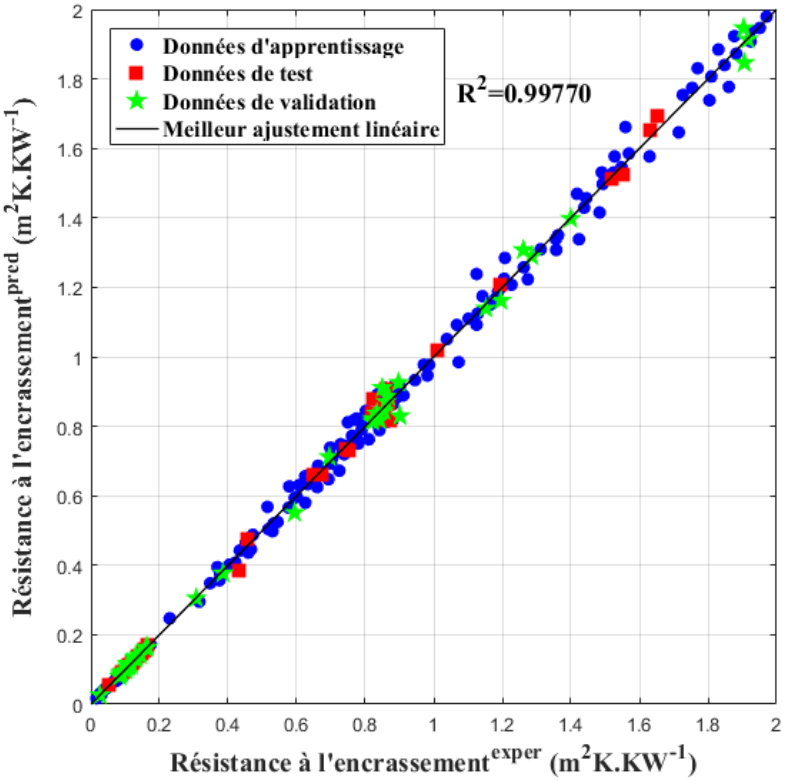


Figure III.3.2 : Résistance à l'encrassement expérimentale vs prévue (tous les ensembles de données)

Le résidu des valeurs prédites de la résistance à l'encrassement par rapport aux valeurs expérimentales du présent modèle est illustré à la **Figure III.3.3**. 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 erreur systématique dans le développement du modèle actuel.

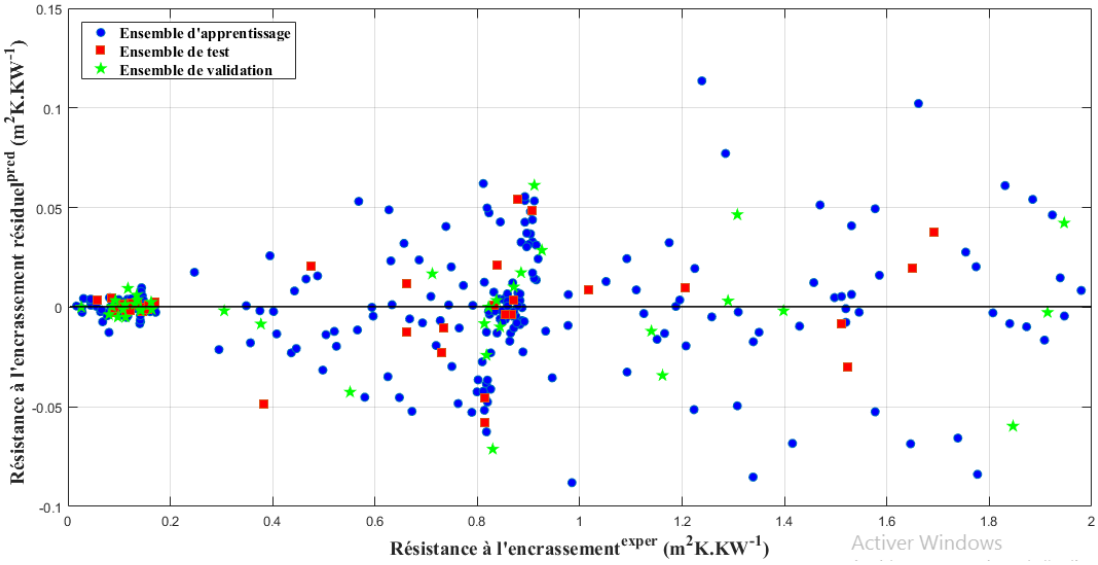
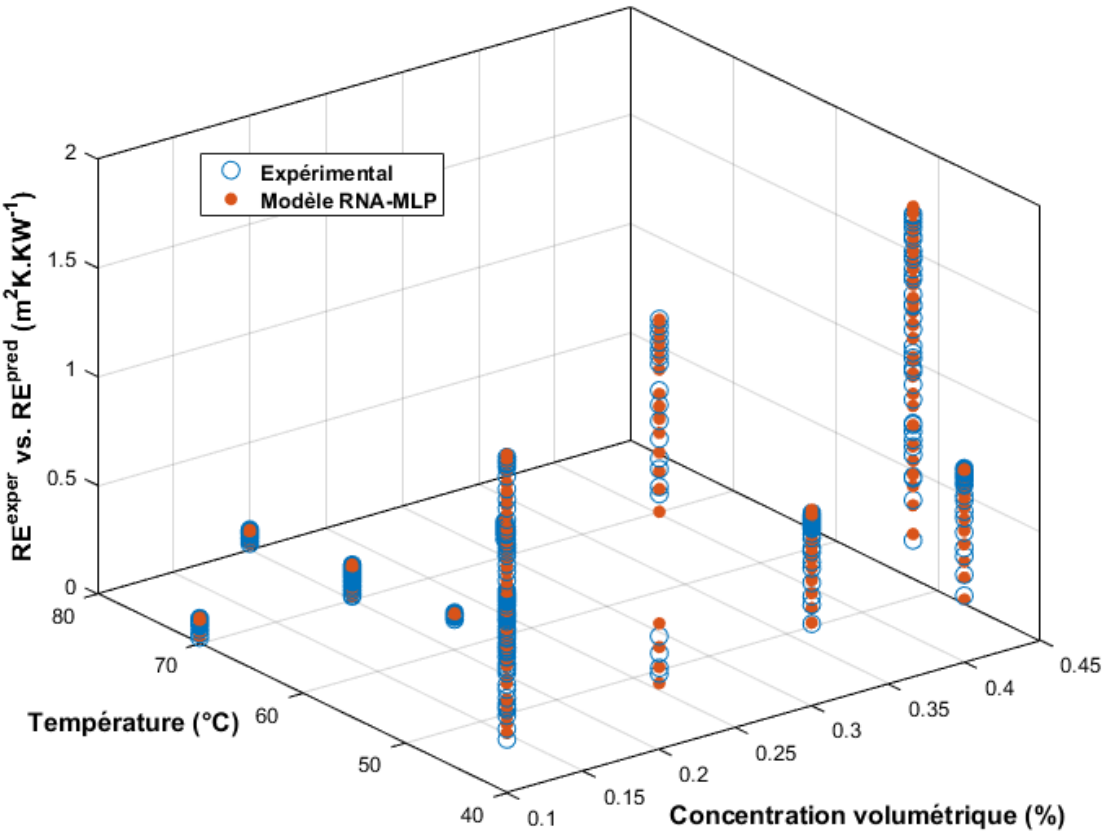
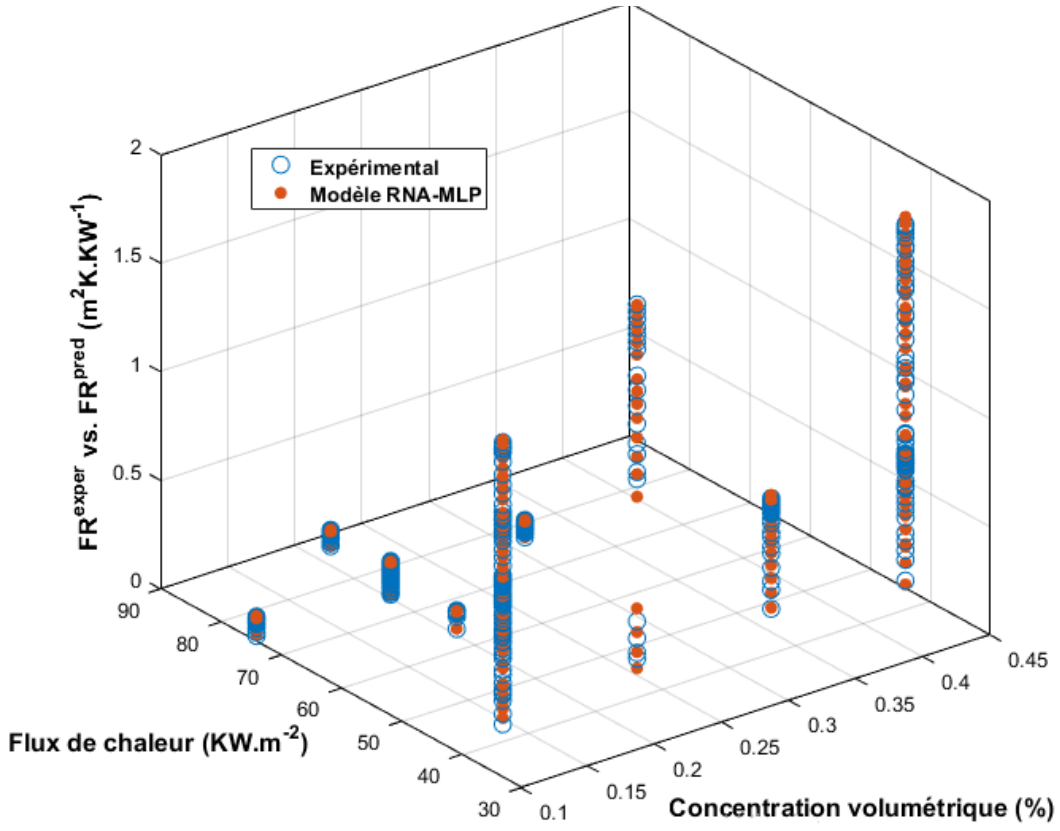


Figure III.3.3: Représentation graphique des valeurs résiduelles calculées de la résistance à l'encrassement RE à partir du modèle RNA-MLP par rapport à leurs valeurs expérimentales pour les ensembles d'apprentissage, de test et de validation

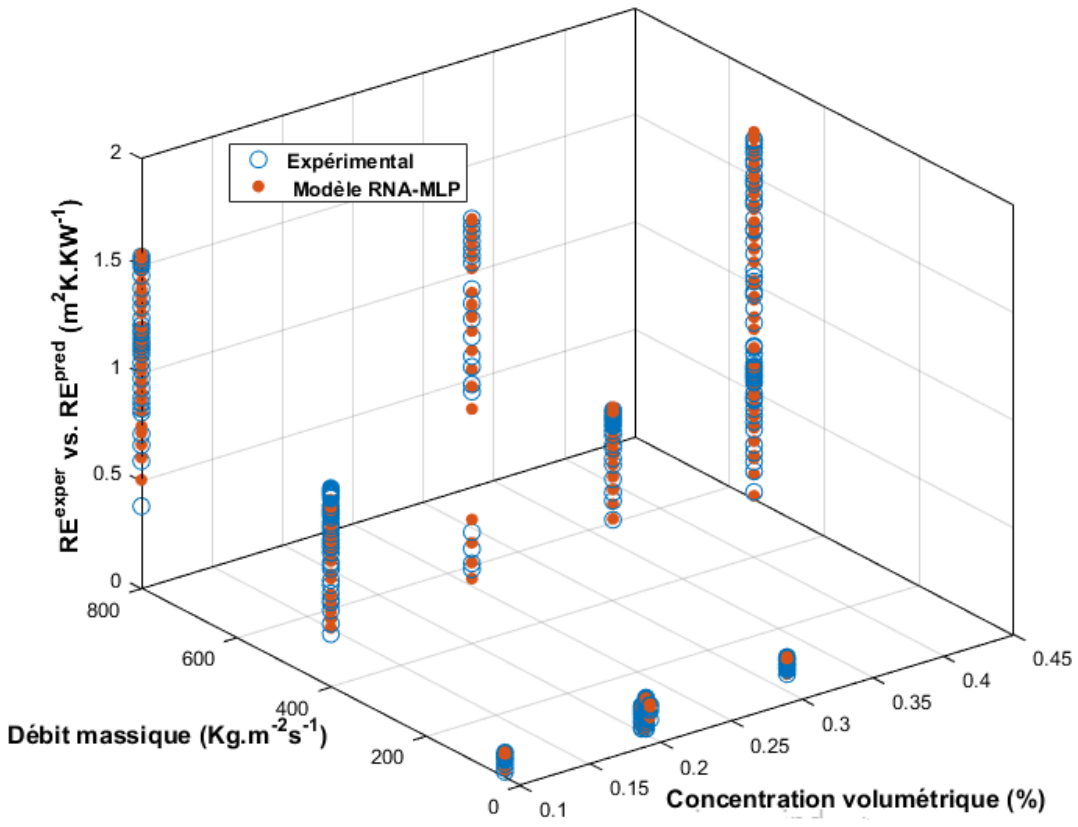
Une fois que le réseau a été créé et que tous les poids et biais ont été initialisés par l'utilisation du modèle RNA-MLP, le réseau est prêt à être formé. Au cours de la formation, les poids et biais du réseau ont été systématiquement mis à jour pour minimiser une fonction de performance MSE de cettecontribution entre la sortie prédite (cible) et la sortie réseau, [297]. Pour une meilleure visualisation, la **Figure III.3.4** montre les tracés tridimensionnels de distribution de tous les ensembles de données expérimentaux comparés au modèle RNA-MLP pour prédire la résistance à l'encrassement des nano-fluides (MgO-eau et CuO-eau) dans l'échangeur de chaleur en fonction de différents entrées (temps, concentration volumétrique, flux de chaleur, débit massique, température d'entrée, conductivité thermique), et il confirme une excellente performance de prédiction d'RNA-MLP.



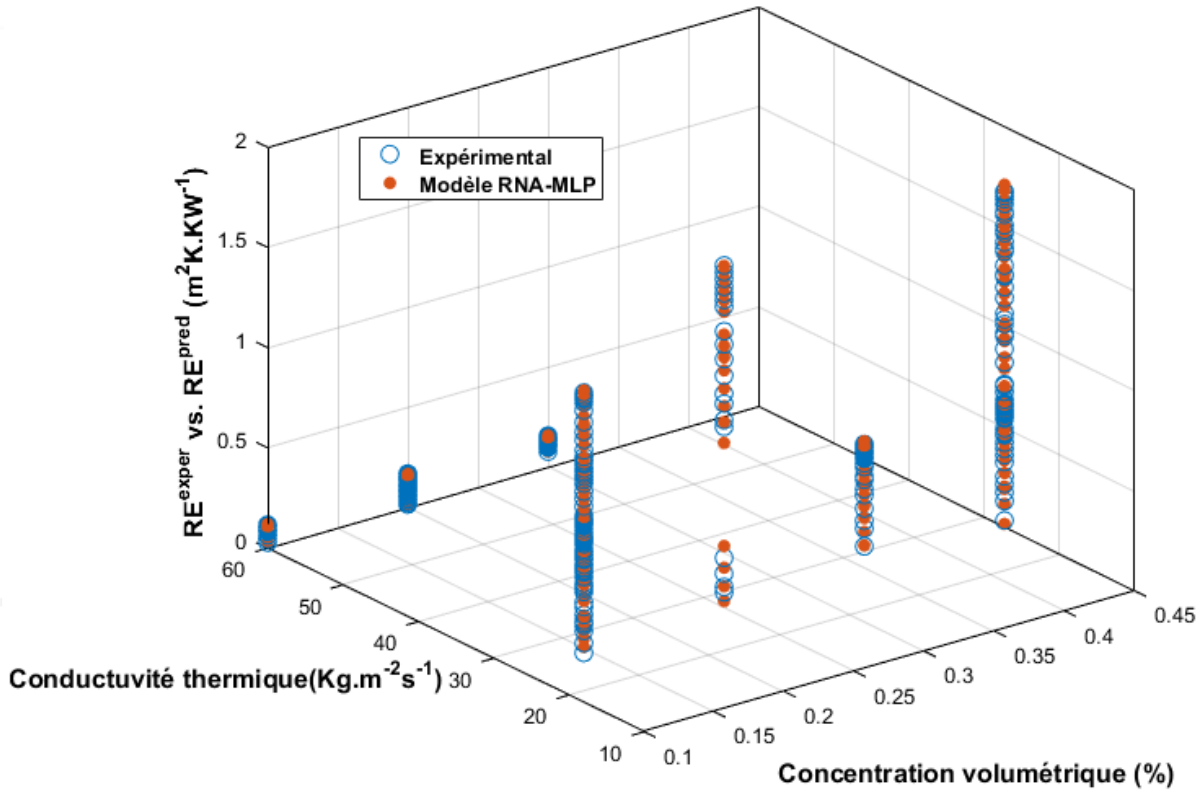
(a)


Expérimental
Modèle RNA-MLP
FR^exper vs. FR^pred (m²K.KW⁻¹)
Flux de chaleur (KW.m⁻²)
Concentration volumétrique (%)

(b)


Expérimental
Modèle RNA-MLP
RE^exper vs. RE^pred (m²K.KW⁻¹)
Débit massique (Kg.m⁻²s⁻¹)
Concentration volumétrique (%)

(c)



(d)

Figure III.3.4: Distribution de tous les ensembles de données (a, b, c et d) entre l'expérimentale et RNA-MLP prévue de la résistance à l'encrassement par rapport aux paramètres d'entrée

III.3.4.1. Configuration optimale du modèle de prédiction de réseau neurone

La configuration optimale de la prédiction du réseau de neurone dépend du nombre de neurones cachés, de la fonction d'activation, du taux d'apprentissage et de la taille de la population, [319].

La méthode d'essai et d'erreur est utilisée pour déterminer le nombre optimal de neurones. Avec l'augmentation du nombre de neurones, la précision de prédiction du réseau neurone est considérablement améliorée. Dans cette contribution, le nombre de neurones est de 1 à 30, et l'effet du nombre de neurones sur MSE et R^2 est montré sur la **Figure III.3.5**. On peut voir que lorsque le nombre de neurones augmente, le MSE diminue et R^2 progressivement augmente. Afin de garantir la précision de la prédiction du réseau neurone, le meilleur réseau est sélectionné à 20 neurones.

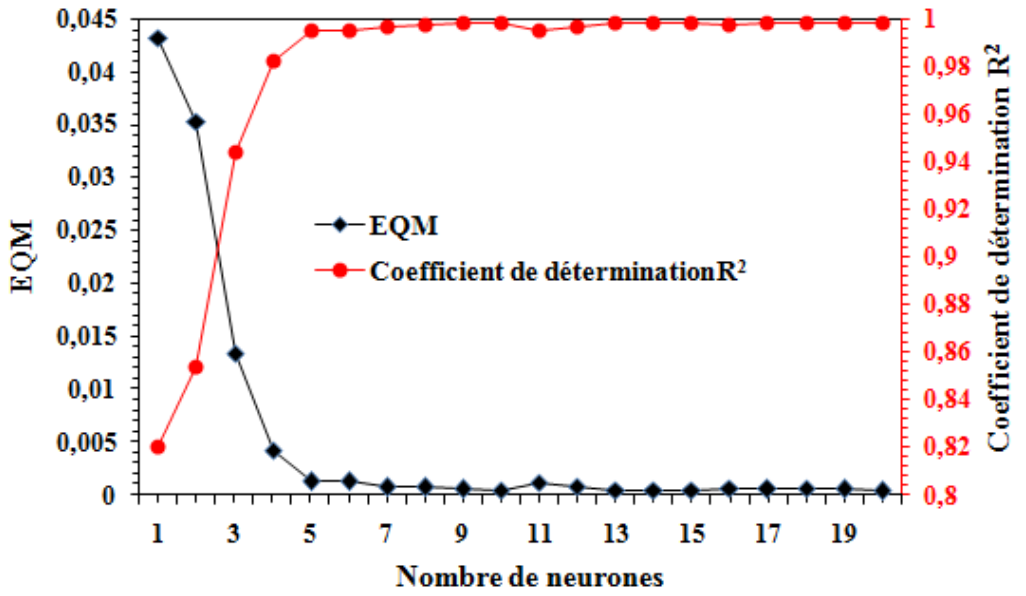


Figure III.3.5 : L'effet du nombre de neurones pour MSE et R^2

Les résultats de la comparaison des erreurs de différents algorithmes d'apprentissage sont présentés sur la **Figure III.3.6**. On peut voir que l'algorithme de *Levenberg-Marquart* a la valeur MSE laplus basse et la valeur R^2 la plus élevée. Par conséquent, l'algorithme de *Levenberg-Marquart* sélectionné dans cette contribution est utilisé comme algorithme d'apprentissage du réseau de neurone.

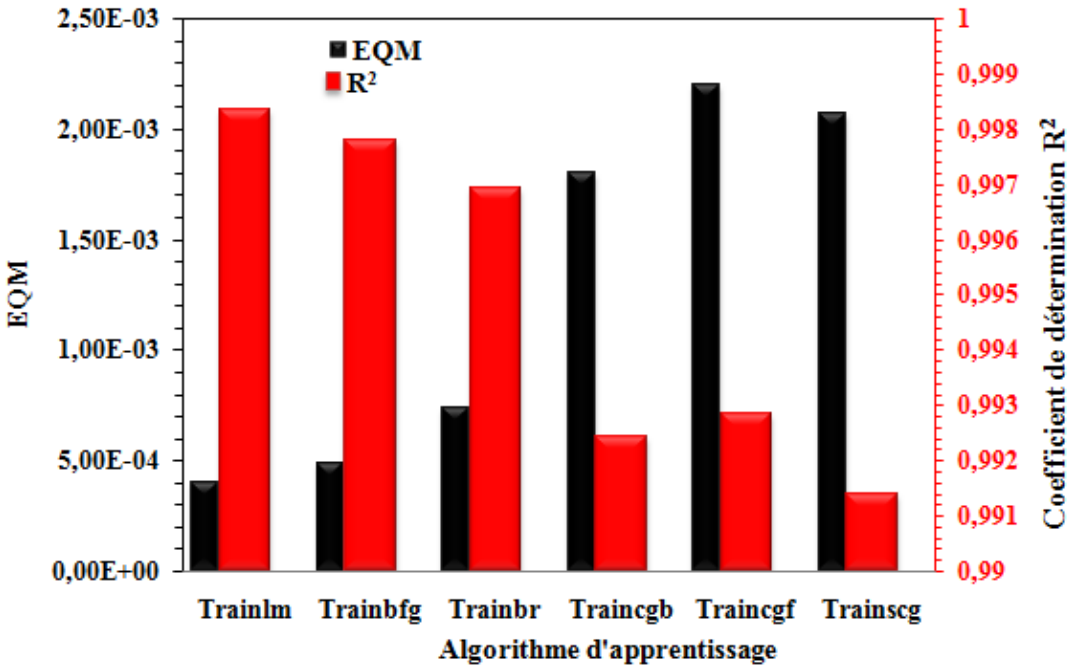


Figure III.3.6 : L'effet de l'algorithme d'apprentissage pour MSE et R^2

III.3.4.2. Validation du modèle RNA

Pour valider notre modèle RNA-MLP développé, une comparaison approximative entre les résultats de la corrélation proposée avec les données expérimentales de Nikkhah et al. [310] pour un nano-fluide à une concentration volumétrique de 0,4% en poids et à deux températures de surface (paroi) (Ts) différentes, la comparaison est présentée sur la **Figure III.3.7**. On peut voir la précision et la validité du modèle neuronal développé pour la prédiction de la résistance à l'encrassement lors de l'écoulement du nano-fluide dans l'échangeur de chaleur.

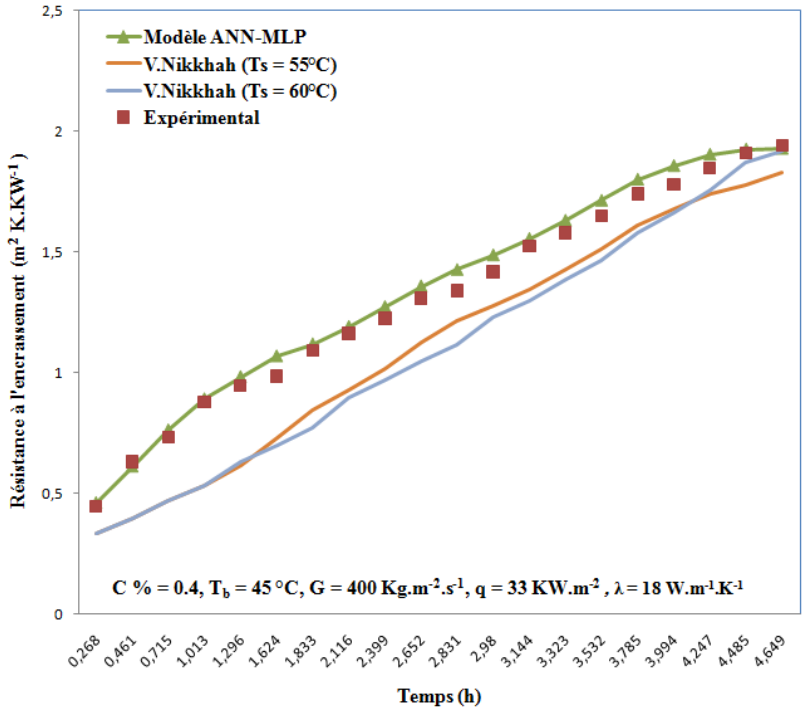


Figure III.3.7 : Comparaisons de la prédiction RNA de RE avec les données expérimentales de nano-fluides (CuO-eau) et corrélations empiriques dans l'échangeur de chaleur

III.3.4.3. Détermination de l'importance de chaque variable d'entrée

Afin d'étudier les impacts des paramètres d'entrée sélectionnés aux sorties prévues, une étude de sensibilité est réalisée, où le modèle qui a été choisi comme exemple d'application de l'étude a 6 entrées, 1 sortie et 20 neurones dans sa couche cachée; il utilise la méthode Min – Max comme technique de normalisation et "trainlm" comme algorithme d'apprentissage. La matrice des poids des réseaux neuronaux du **Tableau III.3.3** peut être utilisée pour déterminer l'importance relative des différentes variables d'entrée sur la variable de sortie.

Garson, [274] a proposé une équation basée sur la partition des poids de connexion:

$$I_J = \frac{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_0}\right|\right)}{\sum_{k=1}^{k=N_i}\left\{\sum_{m=1}^{m=N_h}\left(\left(\left|w_{j_m}^{i_n}\right| \Big/ \sum_{k=1}^{N_i}\left|w_{k_m}^{i_h}\right|\right)\times\left|w_{m_n}^{h_0}\right|\right)\right\}} \qquad \text{(III.3.10)}$$

Où I_j est l'importance relative de la j^{ème} variable d'entrée sur la variable de sortie; N_i et N_h sont le nombre de neurones d'entrée et cachés, respectivement; w est les poids de connexion; les exposants i, h et o se réfèrent respectivement aux couches d'entrée, cachées et de sortie; et les indices k, m et n se réfèrent respectivement aux couches d'entrée, cachées et de sortie, [274].

L'importance relative des variables d'entrée calculées par **l'Eq. (III.3.10)** est représenté sur la **Figure III.3.8.** On peut voir que logiquement, les diverses variables d'entrée ont les effets importants sur la résistance à l'encrassement.

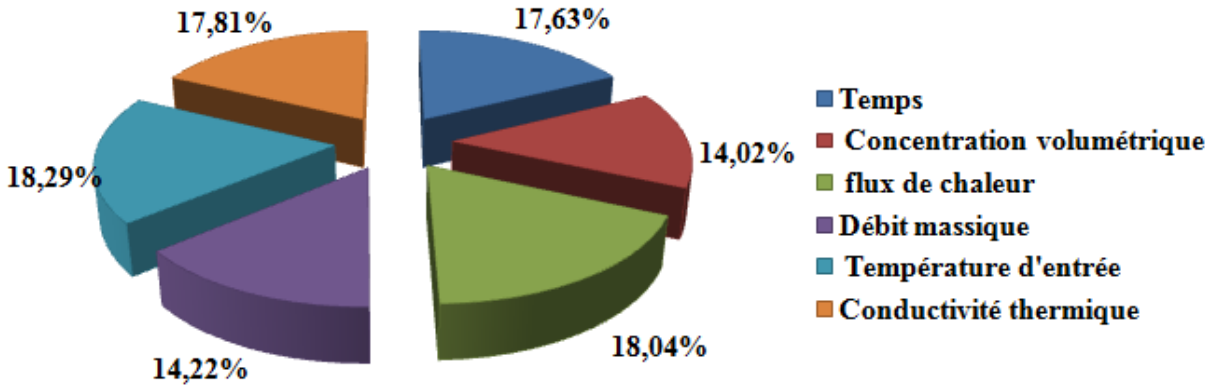


Figure III.3.8 : Importance relative (%) des variables d'entrées sur la valeur de la résistance à l'encrassement calculée

D'après les résultats obtenus, on peut voir clairement que toutes les variables choisies comme entrées ont un effet important sur la résistance à l'encrassement avec des proportions très similaires.

La température d'entrée semble être la variable la plus influente (18,29 %) suivie du flux de chaleur (18,05 %) car ils améliorent les réactions chimiques et de cristallisation. Kukulka, D. J., and Devgun, M. 2007, Setoodeh, H. et al 2015, [320-321], l'augmentation du flux de chaleur améliore le mouvement des particules dans la région proche de la paroi et renforce le transport Prodanovic, V. et al 2002, [322].

La conductivité thermique arrive en troisième position (17,81 %), son effet peut être lié à la nature des surfaces des matériaux. Les matériaux lisses à faible conductivité thermique ont tendance à offrir une résistance à l'encrassement inférieure à celle des

matériaux rugueux à haute conductivité thermique. Al-Janabi, A. et al 2011, Ghahdarijani, A. M. et al 2017, [323-324].

Le temps avec 17,63% d'importance a également un effet significatif sur la résistance à l'encrassement, car la sédimentation des particules instables augmente, la conductivité thermique des nano-fluides diminue. Al-Janabi, A. et al 2011, Ghahdarijani, A. M. et al 2017, [323-324].

Le débit massique contribue à 14,22 % d'importance relative sur la résistance à l'encrassement, ceci est principalement dû à la force de cisaillement à travers la paroi. Un fluide à faible vitesse produit une contrainte de cisaillement plus faible et garantit une forte adhérence des impuretés.La valeur de la résistance à l'encrassement diminue progressivement lorsque le débit massique augmente. Zhan, F. et al 2016, Peyghambarzadeh, S. M. et al 2013, [325-309].

Le dernier paramètre est la concentration volumétrique dont l'importance de 14,02 %. Comme indiqué dans les travaux d'Ojaniemi, U. et al 2012, Awais, M. et Bhuiyan, AA 2019, [326-305], l'augmentation de la concentration augmente la fréquence de contact entre la paroi et les particules dans le flux principal, ce qui accélère la vitesse de dépôt.

La matrice de poids et de biais est donnée en **Tableau III.3.3.**

Tableau III.3.3: Les valeurs de poids et de biais de chaque couche déterminées à l'aide du réseau RNA-MLP optimal.

numbre de neurones	IW {1.1}						b {1}	LW {2.1}	b {2}
	Temps	Concentration volumétrique	flux de chaleur	Débit massique	Température D'entrée	Conductivité thermique	1	Résistance d'encrassement	2
1	0.03824	-0.00337	0.08964	0.01764	0.06472	0.01024	2.30152	0.27324	0.0267
2	-0.07627	-0.00255	-0.00960	0.07997	0.06803	0.03703	-2.06285	-0.21286	
3	0.05660	-0.02655	0.10080	-0.00724	0.04699	0.04197	1.81084	0.23622	
4	-0.72509	-0.43681	1.07781	-0.08223	0.15910	-0.48041	0.96047	-0.39881	
5	-8.19613	-2.71585	1.99234	0.91850	-1.12335	-1.07998	-9.08576	2.86256	
6	-0.34532	-0.98860	-0.43978	0.15854	-0.44154	-0.57649	-0.40645	1.46076	
7	-8.74456	-0.39974	1.80089	0.82643	-0.01131	-3.34021	-7.92236	-2.21943	
8	-0.15460	-2.98357	0.39406	0.44654	-1.18418	-0.13286	-1.16851	-1.07664	
9	10.58433	-4.27753	-5.14578	-1.28542	0.20744	1.98948	7.76020	1.15509	
10	-10.1436	-5.07401	-1.14196	-7.91266	4.84281	7.62904	3.97105	-1.35075	
11	-4.22376	-2.40902	0.55248	1.46030	1.95510	3.33504	1.62353	-6.04152	
12	1.81115	0.22668	-2.51267	-0.20894	-0.60086	1.04547	1.29239	5.36764	
13	9.04397	1.86464	-6.96010	1.57880	-1.24683	-1.41260	8.22601	-5.03703	
14	5.82220	0.25384	0.08034	0.70562	-3.12399	-4.01836	-3.04655	-5.48297	
15	10.91474	1.43822	2.71586	-0.27689	0.74697	2.37565	13.6597	3.15974	
16	1.60177	-0.34321	1.10016	-1.39425	1.38939	1.64980	3.33523	-1.87202	
17	-0.11956	1.28735	0.44296	-0.34866	1.11601	0.29405	1.79225	-2.45023	
18	0.00750	-0.18695	-0.04343	0.03493	0.17718	0.07431	-1.75716	0.02865	
19	-0.10405	-0.06723	-0.04608	0.06244	0.00414	0.02780	-2.05720	-0.28809	
20	0.02252	0.01498	0.06651	-0.01164	0.00281	0.02880	2.30316	0.23449	

III.3.4.4. Programme de résistance à l'encrassement

Un programme informatique a été développé sous MATLAB dans le but d'utiliser le modèle RNA-MLP pour un calcul rapide et facile de la résistance à l'encrassement dans les échangeurs de chaleur avec plus de flexibilité. Cela donne à l'utilisateur toutes les entrées nécessaires à l'exécution du modèle (t: temps, C: concentration volumétrique, q: flux thermique, G: débit massique, T: température, λ: conductivité thermique) pour prédire la résistance à l'encrassement l'échangeur de chaleur pendant l'écoulement du nano-fluide **Figure III.3.9.**

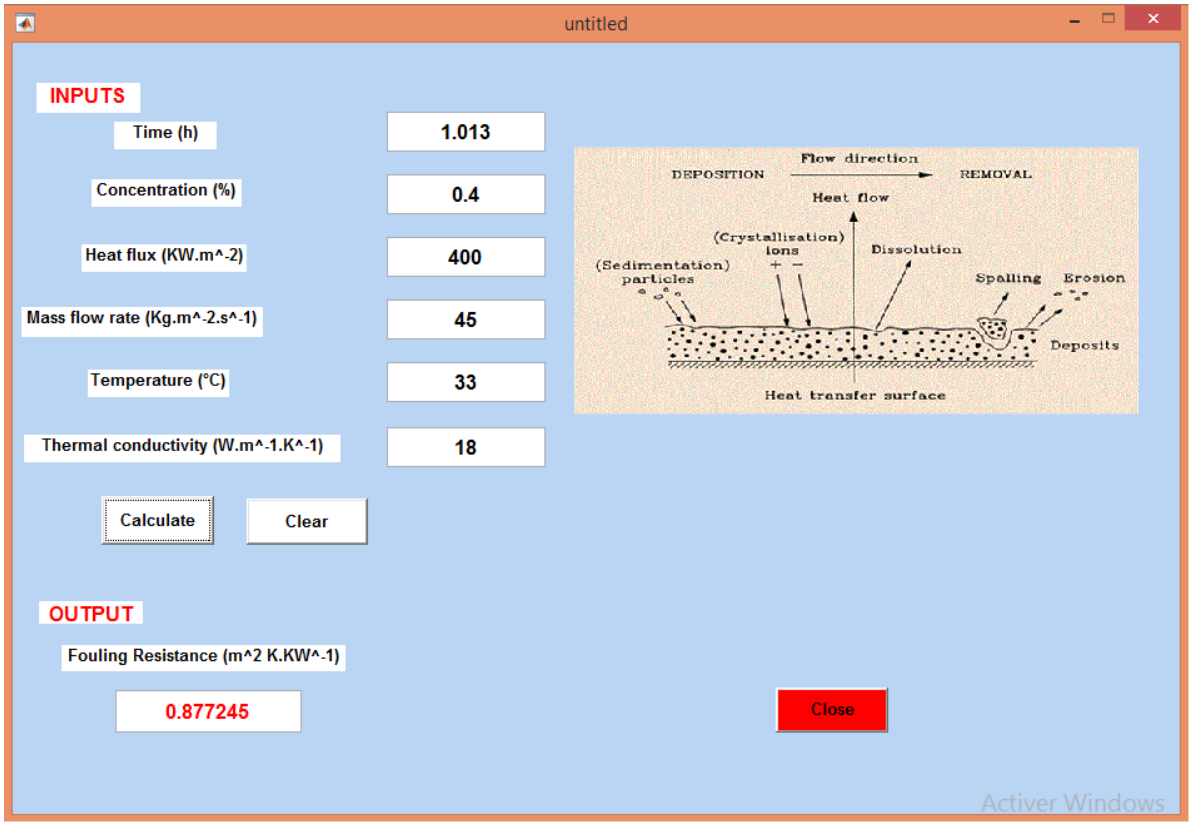


Figure III.3.9 : Interface MATLAB pour la résistance à l'encrassement
(Time : **Temps** ; Concentration : **Concentration volumétrique** ; Heat flux : **Flux de chaleur** ; Masse flux rate : **Débit massique** ; Temperature : **Température d'entrée** ; Thermal conductivity : **Conductivité thermique**)

III.3.5. Conclusion

Dans cette contribution, nous avons développé un modèle de réseau de neurones RNA-MLP pour la prédiction de la résistance à l'encrassement pendant l'écoulement du nano-fluide dans l'échangeur de chaleur, en fonction des variables fondamentales de système d'exploitation telles que le temps, la concentration volumétrique de particules, le flux de chaleur, le débit massique et la température d'entrée, sur l'influence des

particules d'encrassement et des dépôts. L'RNA-MLP est utilisé pour modéliser la résistance à l'encrassement des nano-fluides sur la base de données expérimentale. Un total de 375 points de données expérimentales ont été collectés à partir de la littérature sont divisés en trois sections de données de l'apprentissage, de test et de validation. Des réseaux de structures différentes ont été comparés aux données expérimentales et évalués sur la base des différents critères statistiques. L'architecture RNA-MLP proposée pour l'estimation de la résistance à l'encrassement avec une couche cachée de 20 neurones, qui a été formée avec l'algorithme *Levenberg-Marquardt* et la fonction de transfert tangente sigmoïde dans la couche cachée et la fonction de transfert linéaire dans la couche de sortie. (EQM = 3,9629 x 10^{-4}, ERAM = 1,8922% et R^2 = 0,99835). Sur la base de l'analyse de sensibilité, nous avons constaté que toutes les variables d'entrée avaient un effet significatif sur l'estimation de la résistance à l'encrassement.

La validité du modèle RNA-MLP est montrée dans sa comparaison avec deux corrélations proposées dans la littérature à deux températures de surface Ts (paroi) différentes pour l'échangeur de chaleur et avec les résultats expérimentaux de la résistance à l'encrassement à différents moments.

Par conséquent, il est conclu que le modèle RNA-MLP développé dans cette contribution peut être utilisé avec succès pour fournir une prédiction précise de la résistance à l'encrassement.

Conclusion générale

La complexité de l'analyse des échangeurs de chaleur doit être due à sa géométrie et aux phénomènes physiques impliqués lors de l'échange de chaleur entre les fluides. La modélisation de l'échangeur de chaleur joue un rôle très important dans l'analyse thermique des échangeurs de chaleur. Les méthodes d'intelligence artificielle sont des puissants modèles informatiques capables de capturer et de représenter des relations d'entrée/sortie complexes.

L'objectif de cette thèse est de modéliser le phénomène de l'encrassement des échangeurs de chaleur. Après une synthèse bibliographique, le travail que nous avons abordé dans cette thèse s'articule sur trois contributions :

Dans la contribution préliminaire, nous avons développé un modèle neuronale qui prédit la résistance à l'encrassement d'un échangeur de chaleur tubulaire à contre-courant fonctionnant avec de l'eau et du lait. Pour cela, deux méthodes ont été utilisées à savoir les réseaux de neurones artificiels (RNA) et les machines à vecteurs de support (SVM). Les résultats montrent que le modèle RNA a montré de meilleures performances de prédiction par rapport au modèle SVM en termes d'erreur relative absolue moyenne (ERAM%) de {0.0322, 0.0719} et le coefficient de corrélation (R) de {0.99999, 0.99977} respectivement. Il est conclu que le modèle RNA est capable de prédire la résistance à l'encrassement avec une grande précision.

Dans la deuxième contribution, une méthodologie pour l'élaboration d'un réseau de neurones artificiels RNA d'un échangeur-condenseur d'une centrale nucléaire a été recommandée avec de grandes chances d'atteindre une solution optimale. De plus, sur la base du modèle, une méthodologie a été développée pour estimer les conditions de fonctionnement optimales à partir d'RNAi lors qu'il est nécessaire d'obtenir un résultat optimal pour les entrées connues avec la résistance à l'encrassement requise. La méthode est basée sur test-erreur pour déterminer la structure interne du réseau: l'algorithme d'apprentissage, l'architecture du réseau, méthode d'optimisation simplex de Nelder-Mead. On note que l'erreur "ERAM" dans le modèle optimal RNA atteint 0.1238%. En plus, le modèle donne une erreur quadratique moyenne (REQM) de $3{,}6588 \times 10^{-07}$, un coefficient de corrélation R de 0,99996 et les entrées RNA ont été estimés en utilisant RNAi avec un écart relatif moyen qui ne dépasse pas 0,095%. On peut en déduire à partir des résultats que la méthodologie d'optimisation proposée est fiable pour estimer et/ou prédire la résistance à l'encrassement de l'échangeur-condenseur.

Dans la troisième contribution nous avons fait la prédiction de la résistance à l'encrassement des nano-fluides (MgO-eau et CuO-eau) dans un échangeur de chaleur. Une base de données de 375 valeurs de la résistance à l'encrassement a été recueillie à partir d'articles publiés récemment. Cette contribution a montré que l'utilisation des nano-fluides pour améliorer l'intensification de l'échange thermique, avec les données expérimentales de l'échangeur de chaleur en fonction du temps, de la concentration volumétrique, du flux thermique, du débit massique et de la température d'entrée du fluide comme des entrées de modèle a donné une performance acceptable pour notre modèle RNA-MLP considéré. Avec une erreur quadratique moyenne (EQM = 3,9629 x 10^{-4}) et un coefficient de détermination (R^2 = 0.99835) entre les valeurs expérimentales et calculées pour notre modèle RNA-MLP.

La performance et la validité du notre modèle RNA-MLP est montrée dans sa comparaison avec deux corrélations proposées dans la littérature à deux températures de surface Ts (paroi) différentes pour l'échangeur de chaleur et avec les résultats expérimentaux de la résistance à l'encrassement à différents moments.

Il est conclu que le modèle RNA-MLP développé dans cette contribution peut être utilisé avec succès pour fournir une prédiction précise de la résistance à l'encrassement. **En perspectives**, tout en estimant avoir atteint notre objectif tracé pour cette étude, nous envisagerons :

- Appliquer d'autre méthodes d'intelligence artificiel, telles que le "Deep Learning" dans le but de prédiction/corrélation de la résistance à l'encrassement.
- Des travaux futurs pourraient être mis au point pour étudier la modélisation par les systèmes hybrides comme RNA-PSO, RNA-AG,…
- Simulation de l'encrassement des échangeurs de chaleur sous code ANSYS-FLUENT en utilisant le couplage avec des réseaux de neurones artificiels (RNA).
- Des réseaux aux dynamiques plus complexes seraient également intéressants à modéliser.

Références bibliographiques

[1] Bontemps, LA., Garrigue, A., Goubier, C., Huetz, J., Marvillet, C., Mercier, P., Vidil, R. (1993). Techniques de l'ingénieur, Traité Mécanique et Chaleur, B2340 à B2344, France.

[2] Finkbeiner, F., Gonard, T. &Filiol, B. (1993). Echangeurs thermiques: Enjeux, marchés, technologie et politique d'innovation. Editions européennes Thermique et Industrie (EETI), France.

[3] Bott, T. R. (1992). Heat exchanger fouling. The challenge. Bohnet, M., Bott, TR.

[4] Bott, T. R. (1995). Fouling of heat exchangers. Elsevier.

[5] Goyhenetche, M. (1991). Diagnostic technique et économique de l'encrassement des équipements de transfert thermique dans l'industrie française, Michel Goyhenetche Consultants, France.

[6] Pritchard, A. M. (1988). The economics of fouling. In Fouling Science and Technology (pp. 31-45). Springer, Dordrecht.

[7] Sheikh, A. K., Zubair, S. M., Younas, M., and Budair, M. O. (2000). A risk based heat exchanger analysis subject to fouling: Part II: Economics of heat exchangers cleaning. Energy, 25(5), 445-461.

[8] Kern, D. (1959). A theoretical analysis of thermal surface fouling. Br. Chem. Eng., 4, 258-262.

[9] L. PEREZ. (2003). D´développement, étude de performances et intégration de sonde thermique pour la caractérisation de l'encrassement d'échangeur tubulaires à courants croisés. Phd thèse, L'école nationale supérieure d'arts et métiers.

[10] Gudmundsson, O., Palsson, O. P., Palsson, H., and Lalot, S. (2009). Fouling detection a cross-flow heat exchanger based of physical modlling.

[11] Jonsson, G. R., Lalot, S., Palsson, O. P., and Desmet, B. (2007). Use of extended Kalman filtering in detecting fouling in heat exchangers. International journal of heat and mass transfer, 50(13-14), 2643-2655.

[12] Afgan, Schlunder, Ozisik, Sacaduraafgan V, S. (1993). Heat Exchangers; Design and Theory, Source Book, Editions Mac Graw-Hill.

[13] Perz, L. Batsale, J.C. Ladevie, B, Tochon P. (2003). Mise Au Point D'une Son De La Détection D'encrassement Pour Echangeurs Tubulaires. Congrès Français De Thermique .Sft P. 681-686, 200.

[14] Sacadura J, F. (1993). Initiation Aux Transfert Thermiques. Edition Lavoisier. et Ozisik M.N, Heat Conduction, Editions John Wily and Sons, New –York.

[15] Finkbeiner F, Gonad, T, Et Filiol, B. (1993). Echangeurs Thermiques Enjeux Marche, Technologie Et Politique D'innovation. Editions Européennes Thermiques Et Industries (ETI), France.

[16] BontempsA., Garrigue A., Goubier C., Huetz J.,Marvillet C., MercierP., et ValidR., Echangeur de chaleur – Technique de l'Ingénieur, Traité Génie Énergétique.

[17] Llinares Fontdevila, A. (2004). Fouling of a double pipe heat exchanger. (Doctoral dissertation, Dublin City University).

[18] Epstein, N. (1988). General thermal fouling models. In Fouling Science and Technology. Springer, Dordrecht, 15-30.

[19] Ritter, R. B., and Suitor, J. W. (1977). Fouling Research of Copper and Its Alloys, at Battele OTEC Biofouling and Corrosion Symposium. Seattle, Washington.

[20] Hopkins, R. M., and Epstein, N. (1974). Fouling of heated stainless steel tubes by a flowing suspension of ferric oxide in water. In International Heat Transfer Conference Digital Library. Begel House Inc.

[21] H&C Heat Transfer Solutions Inc (2008-2021). 799 Esser Crescent Sarnia Ontario CANADA N7S5W8.

[22] Müller-Steinhagen, H., Malayeri, M. R., and Watkinson, A. P. (2011). Heat exchanger fouling: mitigation and cleaning strategies.

[23] Al-Hallaf, W. A. A. (2013). Theoretical study on heat transfer in the presence of fouling. Iraqi Journal of Chemical and Petroleum Engineering, 14(1), 47-53.

[24] Panagiotidis, I., Vafiadis, K., Tourlidakis, A., and Tomboulides, A. (2015). Study of slagging and fouling mechanisms in a lignite-fired power plant. Applied Thermal Engineering, 74, 156-164.

[25] Ibrahim, S. M., and Attia, S. I. (2015). The influence of the condenser cooling seawater salinity changes on the thermal performance of a nuclear power plant. Progress in Nuclear Energy, 79, 115-126.

[26] Boxler C. (2014). Fouling by milk constituents and cleaning of modified surfaces. Thèse de doctorat. Braunschweig, Germany: Fakultätfür Maschinenbau, Technischen Universität Carolo-Wilhelmina.

[27] Somerscales, E. F., and Bergles, A. E. (1997). Enhancement of heat transfer and fouling mitigation. Advances in heat transfer, 30, 197-253.

[28] Mansoori, G. A. (2001, May). Deposition and fouling of heavy organic oils and other compounds. In 9th International Conference on Properties and Phase Equilibria for Product and Process Design.

[29] Benning, R., Petermeier, H., Delgado, A., Hinrichs, J., Kulozik, U., and Becker, T. (2003). Process design for improved fouling behaviour in dairy heat exchangers using a hybrid modelling approach. Food and Bioproducts Processing, 81(3), 266-274.

[30] Grijspeerdt, K., Mortier, L., De Block, J., and Van Renterghem, R. (2004). Applications of modelling to optimise ultra high temperature milk heat exchangers with respect to fouling. Food Control, 15(2), 117-130.

[31] Jun, S., & Puri, V. M. (2005). Fouling models for heat exchangers in dairy processing: a review. Journal of food process engineering, 28(1), 1-34.

[32] Mahdi, Y., Mouheb, A., and Oufer, L. (2009). A dynamic model for milk fouling in a plate heat exchanger. Applied mathematical modelling, 33(2), 648-662.

[33] Epstein, N. (1981). Fouling of HeatExchangers. In Advanced Course in Heat Exchangers: Theory and Practice. ICHMT Symposium, Begel House Inc.

[34] Knudsen J.G, Somerscales E, F, C. (1975). Equipment; Hemisphere, Wash DC.

[35] Somerscales, E, F, C, Knudsen, J, G, (1977). Personal Communication, (1), 1-4.

[36] Nancollas, G. H., and Reddy, M. M. (1971). The crystallization of calcium carbonate. II. Calcite growth mechanism. Journal of colloid and interface science, 37(4), 824-830.

[37] Rodier, J. (1971). L'analyse Chimique Et Physicochimique De L'eau. Editions Dunod.

[38] Karabelas, A. J. (2002). Scale formation in tubular heat exchangers—research priorities. International Journal of Thermal Sciences, 41(7), 682-692.

[39] Leconte, J. Protection Contre La Corrosion. Techniques De L'ingénieurA830.

[40] Glade, H., Krömer, K., Stärk, A., Loisel, K., Odiot, K., Nied, S., and Essig, M. (2013). Effects of tube material on scale formation and control in multiple-effect distillers. In The International Desalination Association World Congress on Desalination and Water Reuse.

[41] Epstein, N. (1981). Fouling: Technical Aspects In Fouling Of Heat Transfer Equipment, Somerscales Efc, Kundsen J G.Hemispheres WASHDCP3.

[42] Memento "Technique De L'eau De Degremont et Nalco" Waters Hand Book- Mac Grawn Hill Book Company.

[43] Froment, G, F. (1991). Fouling Of Heat Transfer Surfaces by Coke Formation in Petrochemical Reactor Idem P 411.

[44] Lund, D.Sandhuc, N. (1998). Chemical Reaction Fouling Due To Foods Staffs Idem P 437.

[45] Boxler C. (2014). Fouling by milk constituents and cleaning of modified surfaces. Thèse de doctorat. Braunschweig, Germany: Fakultätfür Maschinenbau, Technischen Universität Carolo-Wilhelmina.

[46] Sheikholeslami, R. (1999). Composite fouling-inorganic and biological: A review. Environmental progress, 18(2), 113-122.

[47] Bouvier, L., Delaplace, G., and Lalot, S. (2019). Continuous Monitoring of Whey Protein Fouling Using a Nonintrusive Sensor. Heat Transfer Engineering.

[48] Epstein, N. (1983). Thinking about heat transfer fouling: a 5× 5 matrix. Heat transfer engineering, 4(1), 43-56.

[49] Grillot, J. M., and Icart, G. (1997). Fouling of a cylindrical probe and a finned tube bundle in a diesel exhaust environment. Experimental thermal and fluid science, 14(4), 442-454.

[50] Brahim, F., Augustin, W., and Bohnet, M. (2003). Numerical simulation of the fouling process. International Journal of Thermal Sciences, 42(3), 323-334.

[51] Nishio, G., Kitani, S., and Takahashi, K. (1974). Thermophoretic deposition of aerosol particles in a heat-exchanger pipe. Industrial and Engineering Chemistry Process Design and Development, 13(4), 408-415.

[52] Rodliffe, R. S., and Means, F. A. (1979). Factors Governing Particulate Corrosion Product Adhesion to Surfaces in Water Reactor Coolant Circuits. Berkeley Nuclear Laboratories, Research Department, Central Electricity Generating Board.

[53] Yiantsios, S. G., and Karabelas, A. J. (1994). Fouling of tube surfaces: modeling of removal kinetics. AIChE journal, 40(11), 1804-1813.

[54] Bohnet, M., Augustin, W., and Hirsch, H. (1997). Influence of fouling layer shear strength on removal behaviour. Understanding heat exchanger fouling and its mitigation, 201-208.

[55] Coletti, F., Ishiyama, E. M., Paterson, W. R., Wilson, D. I., & Macchietto, S. (2010). Impact of deposit aging and surface roughness on thermal fouling: distributed model. AIChE journal, 56(12), 3257-3273.

[56] Awad, M. M. (2011). Fouling of heat transfer surfaces (pp. 505-542). INTECH Open Access Publisher.

[57] Müller-Steinhagen, H. (Ed.). (2000). Heat exchanger fouling: mitigation and cleaning techniques. IChemE.

[58] Bansal, B., and Chen, X. D. (2006). A critical review of milk fouling in heat exchangers. Comprehensive reviews in food science and food safety, 5(2), 27-33.

[59] Guignard C., Verones F., Loerincik Y., Jolliet O. (2009). Environmental / Ecological Impact of the Dairy Sector: Literature review on dairy products for an inventory of key issues. List of environmental initiatives and influences on the dairy sector.

[60] Thackery, P. A., and PA, T. (1980). The cost of fouling in heat exchange plant.

[61] Cornelissen, R. L., and Hirs, G. G. (1999). Thermodynamic optimisation of a heat exchanger. International journal of heat and mass transfer, 42(5), 951-960.

[62] Shah, R. K., and Sekulic, D. P. (2003). Fundamentals of heat exchanger design. John Wiley & Sons.

[63] Yang, K. T. (2008). Artificial neural networks (ANNs): a new paradigm for thermal science and engineering. Journal of heat transfer, 130(9).

[64] Thibault, J., and Grandjean, B. P. (1991). A neural network methodology for heat transfer data analysis. International Journal of Heat and Mass Transfer, 34(8), 2063-2070.

[65] Florian C. (2019). Modélisation et simulation de l'encrassement des échangeurs de chaleur pour eaux géothermales. Thèse de doctorat, Ecole doctorale des sciences exactes et leurs applications (ED211), Université de Pau et des Pays de l'Adour.

[66] Bohnet, M. (1987). Fouling ofheat transfer surfaces. Chemical engineering& technology, 10(1), 113-125.

[67] Kern, D. (1959). A theoretical analysis of thermal surface fouling. Br. Chem. Eng., 4, 258-262.

[68] Krause, S. (1993). Fouling of heat-transfer surfaces by crystallization and sedimentation. International Chemical Engineering (A Quarterly Journal of Translations from Russia, Eastern Europe and Asia); (United States), 33(3).

[69] Beal, A. M., Budtz-Olsen, O. E., Clark, R. C., Cross, R. B., and French, T. J. (1973). Renal and salivary responses to infusion of potassium chloride, bicarbonate and phosphate in Merino sheep. Quarterly Journal of Experimental Physiology and Cognate Medical Sciences: Translation and Integration, 58(3), 251-265.

[70] Burrill, K. A. (1979). Corrosion product transport in water-cooled nuclear reactors. Part III: Boiling water with indirect cycle operation. The Canadian Journal of Chemical Engineering, 57(2), 211-224.

[71] Lister, W. G. (1971). Ternary rings. Transactions of the American Mathematical Society, 154, 37-55.

[72] Taborek, J. (1972). Fouling: The major unsolved problem in heat transfer. Chem. Eng. Prog., 68, 59-67.

[73] Bohnet, M. (2003). Influence of the transport properties of the crystal/heat transfer surface interfacial on fouling behavior. Chemical Engineering & Technology: Industrial Chemistry-Plant Equipment-Process Engineering-Biotechnology, 26(10), 1055-1060.

[74] McCabe, W. L., and Robinson, C. S. (1924). Evaporator scale formation. Industrial & Engineering Chemistry, 16(5), 478-479.

[75] Mankina, N. N., Przhiyalkovskii, M. M., Bulavitskii, Y. M., and Petrova, I. I. (1961). Formation of Iron Deposits in Recirculation Steam Boilers. British Power Engineering, 2(4), 60-63.

[76] Galloway, T. R. (1973). Heat transfer fouling through growth of calcareous film deposits. International Journal of Heat and Mass Transfer, 16(2), 443-458.

[77] Gonionskiy, V. T., Golub, S. I., and Rozen, A. M. (1970). Calculation of heat transfer coefficients during scale formation. Heat Trans. Soviet. Res, 3, 116.

[78] Hasson, D. (1962). Rate of decrease of heat transfer due to scale deposition. Dechema-Monographien, 47, 233-252.

[79] Liddle, C. J., and Teesside, U. K. (1970). Scale formation in cyclic heat transfer processes. Dechema- Monographie, 65, 109-129.

[80] Reitzer, B. J. (1964). Rate of scale formation in tubular heat exchangers. Mathematical analysis of factors influencing rate of decline of over-all heat transfer coefficients. Industrial & Engineering Chemistry Process Design and Development, 3(4), 345-348.

[81] Watkinson, A. P., and Martinez, O. (1975). Scaling of heat exchanger tubes by calcium carbonate.

[82] Xu, Z., Wang, J., Han, Z., and Zhao, Y. (2018). Experimental study on the composite fouling characteristics of calcium carbonate and nanometer magnesia. Journal of Mechanical Science and Technology, 32(1), 497-504.

[83] Bohnet, M. W. (2005). Crystallization fouling on heat transfer surfaces–25 years research in Braunschweig.

[84] Brahim, F., Augustin, W., and Bohnet, M. (2003). Numerical simulation of the fouling process. International Journal of Thermal Sciences, 42(3), 323-334.

[85] Mwaba, M. G., Golriz, M. R., and Gu, J. (2006). A semi-empirical correlation for crystallization fouling on heat exchange surfaces. Applied thermal engineering, 26(4), 440-447.

[86] Zhang, M., Liao, B. Q., Zhou, X., He, Y., Hong, H., Lin, H., and Chen, J. (2015). Effects of hydrophilicity/hydrophobicity of membrane on membrane fouling in a submerged membrane bioreactor. Bio resource technology, 175, 59-67.

[87] Zhang, J., Satti, A., Chen, X., Xiao, K., Sun, J., Yan, X., and Huang, X. (2015). Low-voltage electric field applied into MBR for fouling suppression: Performance and mechanisms. Chemical Engineering Journal, 273, 223-230.

[88] Pääkkönen, T., Dimic-Misic, K., Orelma, H., Pönni, R., Vuorinen, T., and Maloney, T. (2016). Effect of xylan in hardwood pulp on the reaction rate of TEMPO-mediated oxidation and the rheology of the final nanofibrillated cellulose gel. Cellulose, 23(1), 277-293.

[89] Kieffer, R., Mangin, D., Puel, F., and Charcosset, C. (2009). Precipitation of barium sulphate in a hollow fiber membrane contactor, Part I: Investigation of particulate fouling. Chemical engineering science, 64(8), 1759-1767.

[90] Jin, J. B., Liu, D. Q., Zhang, D. D., Yin, Y. H., Zhao, X. Y., and Zhang, Y. F. (2015). Preparation of thin-film composite nanofiltration membranes with improved antifouling property and flux using 2, 2′-oxybis-ethylamine. Desalination, 355, 141-146.

[91] Haghshenasfard, M., and Hooman, K. (2015). CFD modeling of asphaltene deposition rate from crude oil. Journal of Petroleum Science and Engineering, 128, 24-32.

[92] Abu-Khader, M. M. (2012). Plate heat exchangers: Recent advances. Renewable and sustainable energy reviews, 16(4), 1883-1891.

[93] Sommers, A., Wang, Q., Han, X., T'Joen, C., Park, Y., and Jacobi, A. (2010). Ceramics and ceramic matrix composites for heat exchangers in advanced thermal systems—A review. Applied Thermal Engineering, 30(11-12), 1277-1291.

[94] Li, Q., Flamant, G., Yuan, X., Neveu, P., and Luo, L. (2011). Compact heat exchangers: A review and future applications for a new generation of high temperature solar receivers. Renewable and Sustainable Energy Reviews, 15(9), 4855-4875.

[95] Wright, S., Andrews, G., and Sabir, H. (2009). A review of heat exchanger fouling in the context of aircraft air-conditioning systems, and the potential for electrostatic filtering. Applied Thermal Engineering, 29(13), 2596-2609.

[96] Huminic, G., and Huminic, A. (2012). Application of nanofluids in heat exchangers: A review. Renewable and Sustainable Energy Reviews, 16(8), 5625-5638.

[97] Bhutta, M. M. A., Hayat, N., Bashir, M. H., Khan, A. R., Ahmad, K. N., and Khan, S. (2012). CFD applications in various heat exchangers design: A review. Applied Thermal Engineering, 32, 1-12.

[98] Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review. Renewable and Sustainable Energy Reviews, 16(2), 1340-1358.

[99] Cong, T., Su, G., Qiu, S., and Tian, W. (2013). Applications of ANNs in flow and heat transfer problems in nuclear engineering: a review work. Progress in Nuclear Energy, 62, 54-71.

[100] Mellit, A., and Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. Progress in energy and combustion science, 34(5), 574-632.

[101] Kalogirou, S. A. (2003). Artificial intelligence for the modeling and control of combustion processes: a review. Progress in energy and combustion science, 29(6), 515-566.

[102] Kalogirou, S. A. (2000). Applications of artificial neural-networks for energy systems. Applied energy, 67(1-2), 17-35.

[103] Kalogirou, S. A. (2001). Artificial neural networks in renewable energy systems applications: a review. Renewable and sustainable energy reviews, 5(4), 373-401.

[104] Hussain, M. A. (1999). Review of the applications of neural networks in chemical process control—simulation and online implementation. Artificial intelligence in engineering, 13(1), 55-68.

[105] Si Moussa, C. (2010). Modélisation des équilibres de phases à pressions élevées par les réseaux de neurones artificiels, Ecole Nationale Polytechnique.

[106] Vapnik, V. (1998). The support vector method of function estimation. In Nonlinear modeling (pp. 55-85). Springer, Boston, MA.

[107] Li, R., Wang, H. N., He, H., Cui, Y. M., and Du, Z. L. (2007). Support vector machine combined with k-nearest neighbors for solar flare forecasting. Chinese Journal of Astronomy and Astrophysics, 7(3), 441.

[108] Islamoglu, Y. (2003). A new approach for the prediction of the heat transfer rate of the wire-on-tube type heat exchanger––use of an artificial neural network model. Applied Thermal Engineering, 23(2), 243-249.

[109] Hayati, M., Rezaei, A., and Seifi, M. (2009). Prediction of the heat transfer rate of a single layer wire-on-tube type heat exchanger using ANFIS. International Journal of Refrigeration, 32(8), 1914-1917.

[110] Ertunc, H. M., and Hosoz, M. (2008). Comparative analysis of an evaporative condenser using artificial neural network and adaptive neuro-fuzzy inference system. International journal of refrigeration, 31(8), 1426-1436.

[111] Mohanraj, M., Jayaraj, S., and Muraleedharan, C. (2009). Exergy analysis of direct expansion solar-assisted heat pumps using artificial neural networks. International Journal of Energy Research, 33(11), 1005-1020.

[112] Mohanraj, M., Jayaraj, S., and Muraleedharan, C. (2010). Exergy assessment of a direct expansion solar-assisted heat pump working with R22 and R407C/LPG mixture. International Journal of Green Energy, 7(1), 65-83.

[113] Zhao, L. X., and Zhang, C. L. (2010). Fin-and-tube condenser performance evaluation using neural networks. International Journal of Refrigeration, 33(3), 625-634.

[114] Tian, Z., Gu, B., Yang, L., and Liu, F. (2014). Performance prediction for a parallel flow condenser based on artificial neural network. Applied thermal engineering, 63(1), 459-467.

[115] Yang, L., Li, Z. Y., Shao, L. L., and Zhang, C. L. (2014). Model-based dimensionless neural networks for fin-and-tube condenser performance evaluation. International journal of refrigeration, 48, 1-9.

[116] Şahin, A. Ş. (2011). Performance analysis of single-stage refrigeration system with internal heat exchanger using neural network and neuro-fuzzy. Renewable energy, 36(10), 2747-2752.

[117] Islamoglu, Y., Kurt, A., and Parmaksizoglu, C. (2005). Performance prediction for non-adiabatic capillary tube suction line heat exchanger: an artificial neural network approach. Energy conversion and management, 46(2), 223-232.

[118] Heimel, M., Lang, W., and Almbauer, R. (2014). Performance predictions using Artificial Neural Network for isobutane flow in non-adiabatic capillary tubes. International journal of refrigeration, 38, 281-289.

[119] Kumlutaş, D., Karadeniz, Z. H., Avcı, H., and Özşen, M. (2012). Investigation of design parameters of a domestic refrigerator by artificial neural networks and numerical simulations. International journal of refrigeration, 35(6), 1678-1689.

[120] Yigit, K. S., and Ertunc, H. M. (2006). Prediction of the air temperature and humidity at the outlet of a cooling coil using neural networks. International communications in heat and mass transfer, 33(7), 898-907.

[121] Tahavvor, A. R., and Yaghoubi, M. (2011). Prediction of frost deposition on a horizontal circular cylinder under natural convection using artificial neural networks. International journal of refrigeration, 34(2), 560-566.

[122] Akbari, S., Hemingson, H. B., Beriault, D., Simonson, C. J., and Besant, R. W. (2012). Application of neural networks to predict the steady state performance of a run-around membrane energy exchanger. International journal of heat and mass transfer, 55(5-6), 1628-1641.

[123] Akbari, S., Simonson, C. J., and Besant, R. W. (2012). Application of neural networks to predict the transient performance of a run-around membrane energy exchanger for yearly non-stop operation. International journal of heat and mass transfer, 55(21-22), 5403-5416.

[124] Tan, C. K., Ward, J., Wilcox, S. J., and Payne, R. (2009). Artificial neural network modelling of the thermal performance of a compact heat exchanger. Applied Thermal Engineering, 29(17-18), 3609-3617.

[125] Ermis, K. (2008). ANN modeling of compact heat exchangers. International Journal of Energy Research, 32(6), 581-594.

[126] Selbaş, R., Şencan, A., and Kılıç, B. (2009). Alternative approach in thermal analysis of plate heat exchanger. Heat and mass transfer, 45(3), 323-329.

[127] Peng, H., and Ling, X. (2008). Optimal design approach for the plate-fin heat exchangers using neural networks cooperated with genetic algorithms. Applied thermal engineering, 28(5-6), 642-650.

[128] Peng, H., and Ling, X. (2009). Neural networks analysis of thermal characteristics on plate-fin heat exchangers with limited experimental data. Applied Thermal Engineering, 29(11-12), 2251-2256.

[129] Singh, V., Aute, V., and Radermacher, R. (2009). A heat exchanger model for air-to-refrigerant fin-and-tube heat exchanger with arbitrary fin sheet. International journal of refrigeration, 32(7), 1724-1735.

[130] Pacheco-Vega, A., Dı´ az, G., Sen, M., Yang, K. T., and McClain, R. L. (2001). Heat rate predictions in humid air-water heat exchangers using correlations and neural networks. J. Heat Transfer, 123(2), 348-354.

[131] Pacheco-Vega, A., Sen, M., Yang, K. T., and McClain, R. L. (2001). Neural network analysis of fin-tube refrigerating heat exchanger with limited experimental data. International Journal of Heat and Mass Transfer, 44(4), 763-770.

[132] Ding, G. L., Zhang, C. L., and Zhan, T. (2004). An approximate integral model with an artificial neural network for heat exchangers. Heat Transfer—Asian Research: Co-sponsored by the Society of Chemical Engineers of Japan and the Heat Transfer Division of ASME, 33(3), 153-160.

[133] Wu, Z. G., Zhang, J. Z., Tao, Y. B., He, Y. L., and Tao, W. Q. (2008). Application of artificial neural network method for performance prediction of a gas cooler in a CO2 heat pump. International journal of heat and mass transfer, 51(21-22), 5459-5464.

[134] Wang, Q., Xie, G., Zeng, M., and Luo, L. (2006). Prediction of heat transfer rates for shell-and-tube heat exchangers by artificial neural networks approach. Journal of Thermal Science, 15(3), 257-262.

[135] Xie, G. N., Wang, Q. W., Zeng, M., and Luo, L. Q. (2007). Heat transfer analysis for shell-and-tube heat exchangers with experimental data by artificial neural networks approach. Applied Thermal Engineering, 27(5-6), 1096-1104.

[136] Mandavgane, S. A., and Pandharipande, S. L. (2006). Application of optimum ANN architecture for heat exchanger modeling.J. Chem. Technol. 13, 634-639.

[137] Pandharipande, S. L., Siddiqui, M. A., Dubey, A., and Mandavgane, S. A. (2004). Optimising ANN architecture for shell and tube heat exchanger modelling. J.Chem. Technol. 11, 804-810.

[138] Kashani, M. N., Aminian, J., Shahhosseini, S., and Farrokhi, M. (2012). Dynamic crude oil fouling prediction in industrial preheaters using optimized ANN based moving window technique. Chemical Engineering Research and Design, 90(7), 938-949.

[139] Duran, O., Rodriguez, N., and Consalter, L. A. (2009). Neural networks for cost estimation of shell and tube heat exchangers. Expert Systems with Applications, 36(4), 7435-7440.

[140] Fadare, D. A., and Fatona, A. S. (2008). Artificial neural network modeling of heat transfer in a staggered cross-flow tube type heat exchanger. Pacific J. Sci. Technol. 9, 317-323.

[141] Kalogirou, S. A. (2004). Solar thermal collectors and applications. Progress in energy and combustion science, 30(3), 231-295.

[142] Kalogirou, S. A., Panteliou, S., and Dentsoras, A. (1999). Artificial neural networks used for the performance prediction of a thermosiphon solar water heater. Renewable energy, 18(1), 87-99.

[143] Kalogirou, S. A. (2000). Long-term performance prediction of forced circulation solar domestic water heating systems using artificial neural networks. Applied energy, 66(1), 63-74.

[144] Kalogirou, S., Lalot, S., Florides, G., and Desmet, B. (2008). Development of a neural network-based fault diagnostic system for solar thermal applications. Solar Energy, 82(2), 164-172.

[145] Kalogirou, S. A., Mathioulakis, E., and Belessiotis, V. (2014). Artificial neural networks for the performance prediction of large solar systems. Renewable Energy, 63, 90-97.

[146] Facão, J., Varga, S., and Oliveira, A. C. (2004). Evaluation of the use of artificial neural networks for the simulation of hybrid solar collectors. International journal of green energy, 1(3), 337-352.

[147] Sözen, A., Menlik, T., and Ünvar, S. (2008). Determination of efficiency of flat-plate solar collectors using neural network approach. Expert Systems with Applications, 35(4), 1533-1539.

[148] Cetiner, C., Halici, F., Cacur, H., and Taymaz, I. (2005). Generating hot water by solar energy and application of neural network. Applied Thermal Engineering, 25(8-9), 1337-1348.

[149] Dikmen, E., Ayaz, M., Ezen, H. H., Küçüksille, E. U., and Şahin, A. Ş. (2014). Estimation and optimization of thermal performance of evacuated tube solar collector system. Heat and Mass Transfer, 50(5), 711-719.

[150] Farkas, I., and Geczy-Vıg, P. (2003). Neural network modelling of flat-plate solar collectors. Computers and electronics in Agriculture, 40(1-3), 87-102.

[151] Caner, M., Gedik, E., and Keçebaş, A. (2011). Investigation on thermal performance calculation of two type solar air collectors using artificial neural network. Expert Systems with Applications, 38(3), 1668-1674.

[152] Esen, H., Ozgen, F., Esen, M., and Sengur, A. (2009). Artificial neural network and wavelet neural network approaches for modelling of a solar air heater. Expert systems with applications, 36(8), 11240-11248.

[153] Benli, H. (2013). Determination of thermal performance calculation of two different types solar air collectors with the use of artificial neural networks. International Journal of Heat and Mass Transfer, 60, 1-7.

[154] Tyagi, S. K., Pandey, A. K., Pant, P. C., and Tyagi, V. V. (2012). Formation, potential and abatement of plume from wet cooling towers: A review. Renewable and Sustainable Energy Reviews, 16(5), 3409-3429.

[155] Hosoz, M. U. R. A. T., Ertunç, H. M., and Bulgurcu, H. Ü. S. E. Y. İ. N. (2007). Performance prediction of a cooling tower using artificial neural network. Energy Conversion and Management, 48(4), 1349-1359.

[156] Gao, M., Sun, F. Z., Zhou, S. J., Shi, Y. T., Zhao, Y. B., and Wang, N. H. (2009). Performance prediction of wet cooling tower using artificial neural network under cross-wind conditions. International Journal of Thermal Sciences, 48(3), 583-589.

[157] Gao, M., Shi, Y. T., Wang, N. N., Zhao, Y. B., and Sun, F. Z. (2013). Artificial neural network model research on effects of cross-wind to performance parameters of wet cooling tower based on level Froude number. Applied thermal engineering, 51(1-2), 1226-1234.

[158] Islamoglu, Y. (2005). Modeling of thermal performance of a cooling tower using an artificial neural network. Heat transfer engineering, 26(4), 073-076.

[159] Qi, X., Liu, Z., and Li, D. (2008). Numerical simulation of shower cooling tower based on artificial neural network. Energy Conversion and Management, 49(4), 724-732.

[160] Wu, J., Zhang, G., Zhang, Q., Zhou, J., and Wang, Y. (2011). Artificial neural network analysis of the performance characteristics of a reversibly used cooling tower under cross flow conditions for heat pump heating system in winter. Energy and buildings, 43(7), 1685-1693.

[161] Hosoz, M., Ertunc, H. M., and Ozguc, A. F. (2008). Modelling of a direct evaporative air cooler using artificial neural network. International Journal of Energy Research, 32(1), 83-89.

[162] Kiran, T. R., and Rajput, S. P. S. (2011). An effectiveness model for an indirect evaporative cooling (IEC) system: Comparison of artificial neural networks (ANN), adaptive neuro-fuzzy inference system (ANFIS) and fuzzy inference system (FIS) approach. Applied Soft Computing, 11(4), 3525-3533.

[163] Bisoniya, T. S., Kumar, A., and Baredar, P. (2013). Experimental and analytical studies of earth–air heat exchanger (EAHE) systems in India: a review. Renewable and Sustainable Energy Reviews, 19, 238-246.

[164] Kumar, R., Kaushik, S. C., and Garg, S. N. (2006). Heating and cooling potential of an earth-to-air heat exchanger using artificial neural network. Renewable Energy, 31(8), 1139-1155.

[165] Zhang, J., and Haghighat, F. (2009). Convective heat transfer prediction in large rectangular cross-sectional area Earth-to-Air Heat Exchangers. Building and environment, 44(9), 1892-1898.

[166] Zhang, J., and Haghighat, F. (2010). Development of Artificial Neural Network based heat convection algorithm for thermal simulation of large rectangular cross-sectional area Earth-to-Air Heat Exchangers. Energy and Buildings, 42(4), 435-440.

[167] Gang, W., and Wang, J. (2013). Predictive ANN models of ground heat exchanger for the control of hybrid ground source heat pump systems. Applied energy, 112, 1146-1153.

[168] Krzywanski, J., and Nowak, W. (2012). Modeling of heat transfer coefficient in the furnace of CFB boilers by artificial neural network approach. International Journal of Heat and Mass Transfer, 55(15-16), 4246-4253.

[169] Hakeem, M. A., Kamil, M., and Arman, I. (2008). Prediction of temperature profiles using artificial neural networks in a vertical thermo siphon reboiler. Applied Thermal Engineering, 28(13), 1572-1579.

[170] Prieto, M. M., Montanes, E., and Menendez, O. (2001). Power plant condenser performance forecasting using a non-fully connected artificial neural network. Energy, 26(1), 65-79.

[171] Aydın, O., and Baki, M. (2006). An experimental study on the design parameters of a counter flow vortex tube. Energy, 31(14), 2763-2772.

[172] Kocabas, F., Korkmaz, M., Sorgucu, U., and Donmez, S. (2010). Modeling of heating and cooling performance of counter flow type vortex tube by using artificial neural network. International Journal of Refrigeration, 33(5), 963-972.

[173] Uluer, O., Kırmacı, V., and Ataş, Ş. (2009). Using the artificial neural network model for modeling the performance of the counter flow vortex tube. Expert Systems with Applications, 36(10), 12256-12263.

[174] Dincer, K., Tasdemir, S., Baskaya, S., and Uysal, B. Z. (2008). Modeling of the effects of length to diameter ratio and nozzle number on the performance of counter flow Ranque–Hilsch vortex tubes using artificial neural networks. Applied thermal engineering, 28(17-18), 2380-2390.

[175] Amanifard, N., Nariman-Zadeh, N., Borji, M., Khalkhali, A., and Habibdoust, A. (2008). Modelling and Pareto optimization of heat transfer and flow coefficients in microchannels using GMDH type neural networks and genetic algorithms. Energy Conversion and Management, 49(2), 311-325.

[176] Wijayasekara, D., Manic, M., Sabharwall, P., and Utgikar, V. (2011). Optimal artificial neural network architecture selection for performance prediction of compact heat exchanger with the EBaLM-OTR technique. Nuclear Engineering and Design, 241(7), 2549-2557.

[177] Jambunathan, K., Hartle, S. L., Ashforth-Frost, S., and Fontama, V. N. (1996). Evaluating convective heat transfer coefficients using neural networks. International Journal of Heat and Mass Transfer, 39(11), 2329-2332.

[178] Ghajar, A. J., Tam, L. M., and Tam, S. C. (2004). Improved heat transfer correlation in the transition region for a circular tube with three inlet configurations using artificial neural networks. Heat Transfer Engineering, 25(2), 30-40.

[179] Islamoglu, Y., and Kurt, A. (2004). Heat transfer analysis using ANNs with experimental data for air flowing in corrugated channels. International Journal of Heat and Mass Transfer, 47(6-7), 1361-1365.

[180] Colorado, D., Ali, M. E., García-Valladares, O., and Hernández, J. A. (2011). Heat transfer using a correlation by neural network for natural convection from vertical helical coil in oil and glycerol/water solution. Energy, 36(2), 854-863.

[181] Mehrabi, M., and Pesteei, S. M. (2011). Modeling of heat transfer and fluid flow characteristics of helicoidal double-pipe heat exchangers using adaptive neuro-fuzzy inference system (ANFIS). International Communications in Heat and Mass Transfer, 38(4), 525-532.

[182] Kamble, L. V., Pangavhane, D. R., and Singh, T. P. (2014). Experimental investigation of horizontal tube immersed in gas–solid fluidized bed of large particles using artificial neural network. International Journal of Heat and Mass Transfer, 70, 719-724.

[183] Tahseen, T. A., Ishak, M., and Rahman, M. M. (2014). Performance predictions of laminar heat transfer and pressure drop in an in-line flat tube bundle using an adaptive neuro-fuzzy inference system (ANFIS) model. International Communications in Heat and Mass Transfer, 50, 85-97.

[184] Karami, A., Rezaei, E., Rahimi, M., and Khani, S. (2013). Modeling of heat transfer in an air cooler equipped with classic twisted tape inserts using adaptive neuro-fuzzy inference system. Chemical Engineering Communications, 200(4), 532-542.

[185] Akdag, U., and Ozguc, A. F. (2009). Experimental investigation of heat transfer in oscillating annular flow. International Journal of Heat and Mass Transfer, 52(11-12), 2667-2672.

[186] Nuntaphan, A., Vithayasai, S., Vorayos, N., Vorayos, N., and Kiatsiriroat, T. (2010). Use of oscillating heat pipe technique as extended surface in wire-on-tube heat exchanger for heat transfer enhancement. International communications in heat and mass transfer, 37(3), 287-292.

[187] Akdag, U., Komur, M. A., and Ozguc, A. F. (2009). Estimation of heat transfer in oscillating annular flow using artifical neural networks. Advances in engineering software, 40(9), 864-870.

[188] Müller-Steinhagen, H. (1999). Cooling-water fouling in heat exchangers. In Advances in heat transfer (Vol. 33, pp. 415-496). Elsevier.

[189] Riverol, C., and Napolitano, V. (2005). Estimation of fouling in a plate heat exchanger through the application of neural networks. Journal of Chemical Technology & Biotechnology: International Research in Process, Environmental & Clean Technology, 80(5), 594-600.

[190] Lalot, S., and Lecoeuche, S. (2003). Online fouling detection in electrical circulation heaters using neural networks. International Journal of Heat and Mass Transfer, 46(13), 2445-2457.

[191] Jerónimo, M. A. S., Melo, L. F., Braga, A. S., Ferreira, P. J. B. F., and Martins, C. (1997). Monitoring the thermal efficiency of fouled heat exchangers: a simplified method. Experimental Thermal and Fluid Science, 14(4), 455-463.

[192] Aminian, J., and Shahhosseini, S. (2008). Evaluation of ANN modeling for prediction of crude oil fouling behavior. Applied thermal engineering, 28(7), 668-674.

[193] Aminian, J., and Shahhosseini, S. (2009). Neuro-based formulation to predict fouling threshold in crude preheaters. International Communications in Heat and Mass Transfer, 36(5), 525-531.

[194] Lalot, S., and Pálsson, H. (2010). Detection of fouling in a cross-flow heat exchanger using a neural network based technique. International Journal of Thermal Sciences, 49(4), 675-679.

[195] Garcia, R. F. (2012). Improving heat exchanger supervision using neural networks and rule based techniques. Expert Systems with Applications, 39(3), 3012-3021.

[196] Romeo, L. M., and Gareta, R. (2006). Hybrid system for fouling control in biomass boilers. Engineering Applications of Artificial Intelligence, 19(8), 915-925.

[197] Beigzadeh, R., and Rahimi, M. (2012). Prediction of heat transfer and flow characteristics in helically coiled tubes using artificial neural networks. International Communications in Heat and Mass Transfer, 39(8), 1279-1285.

[198] Beigzadeh, R., and Rahimi, M. (2012). Prediction of thermal and fluid flow characteristics in helically coiled tubes using ANFIS and GA based correlations. International Communications in Heat and Mass Transfer, 39(10), 1647-1653.

[199] Zdaniuk, G. J., Chamra, L. M., and Walters, D. K. (2007). Correlating heat transfer and friction in helically-finned tubes using artificial neural networks. International Journal of Heat and Mass Transfer, 50(23-24), 4713-4723.

[200] Xie, G., Sunden, B., Wang, Q., and Tang, L. (2009). Performance predictions of laminar and turbulent heat transfer and fluid flow of heat exchangers having large tube-diameter and large tube-row by artificial neural networks. International Journal of Heat and Mass Transfer, 52(11-12), 2484-2497.

[201] Nasr, M. J., Khalaj, A. H., and Mozaffari, S. H. (2010). Modeling of heat transfer enhancement by wire coil inserts using artificial neural network analysis. Applied Thermal Engineering, 30(2-3), 143-151.

[202] Nasr, M. R. J., and Khalaj, A. H. (2010). Heat transfer coefficient and friction factor prediction of corrugated tubes combined with twisted tape inserts using artificial neural network. Heat transfer engineering, 31(1), 59-69.

[203] HabibiKhalaj, A., Chaibakhsh, A., Sayyaadi, H., and Jafari Nasr, M. R. (2014). Thermo-hydraulic behavior modeling of passive heat transfer enhancement techniques using a soft computing approach. Chemical Engineering Communications, 201(1), 53-71.

[204] Gorenflo, D., Baumhögger, E., Herres, G., and Kotthoff, S. (2014). Prediction methods for pool boiling heat transfer: A state-of-the-art review. International journal of refrigeration, 43, 203-226.

[205] Fronk, B. M., and Garimella, S. (2013). In-tube condensation of zeotropic fluid mixtures: A review. International journal of refrigeration, 36(2), 534-561.

[206] Balcilar, M., Dalkilic, A. S., Suriyawong, A., Yiamsawas, T., and Wongwises, S. (2012). Investigation of pool boiling of nanofluids using artificial neural networks and correlation development techniques. International Communications in Heat and Mass Transfer, 39(3), 424-431.

[207] Wang, W. J., Zhao, L. X., and Zhang, C. L. (2006). Generalized neural network correlation for flow boiling heat transfer of R22 and its alternative refrigerants inside horizontal smooth tubes. International Journal of Heat and Mass Transfer, 49(15-16), 2458-2465.

[208] Scalabrin, G., Condosta, M., and Marchi, P. (2006). Modeling flow boiling heat transfer of pure fluids through artificial neural networks. International Journal of Thermal Sciences, 45(7), 643-663.

[209] Scalabrin, G., Condosta, M., and Marchi, P. (2006). Mixtures flow boiling: modeling heat transfer through artificial neural networks. International journal of thermal sciences, 45(7), 664-680.

[210] Scalabrin, G., Condosta, M., and Marchi, P. (2006). Flow boiling of pure fluids: local heat transfer and flow pattern modeling through artificial neural networks. International journal of thermal sciences, 45(8), 739-751.

[211] Liu, T., Sun, X., Li, X., and Wang, H. (2002). Neural network analysis of boiling heat transfer enhancement using additives. International journal of heat and mass transfer, 45(25), 5083-5089.

[212] Alizadehdakhel, A., Rahimi, M., Sanjari, J., and Alsairafi, A. A. (2009). CFD and artificial neural network modeling of two-phase flow pressure drop. International Communications in Heat and Mass Transfer, 36(8), 850-856.

[213] Porto, M. P., Pedro, H. T., Machado, L., Koury, R. N., Lima, C. U., and Coimbra, C. F. (2014). Genetic optimization of heat transfer correlations for evaporator tube flows. International Journal of Heat and Mass Transfer, 70, 330-339.

[214] Wei, H., Su, G. H., Tian, W. X., Qiu, S. Z., and Yang, X. B. (2010). Study on the onset of nucleate boiling in narrow annular channel by genetic neural network. International communications in heat and mass transfer, 37(6), 596-599.

[215] Wen, X. L., Wang, H. T., and Wang, H. (2012). Prediction model of flow boiling heat transfer for R407C inside horizontal smooth tubes based on RBF neural network. Procedia Engineering, 31, 233-239.

[216] Hall, D. D., and Mudawar, I. (2000). Critical heat flux (CHF) for water flow in tubes—I. Compilation and assessment of world CHF data. International Journal of Heat and Mass Transfer, 43(14), 2573-2604.

[217] Mazzola, A. (1997). Integrating artificial neural networks and empirical correlations for the prediction of water-subcooled critical heat flux. Revue générale de thermique, 36(11), 799-806.

[218] Vaziri, N., Hojabri, A., Erfani, A., Monsefi, M., and Nilforooshan, B. (2007). Critical heat flux prediction by using radial basis function and multilayer perceptron neural networks: a comparison study. Nuclear engineering and design, 237(4), 377-385.

[219] Nafey, A. S. (2009). Neural network based correlation for critical heat flux in steam-water flows in pipes. International Journal of Thermal Sciences, 48(12), 2264-2270.

[220] Cong, T., Chen, R., Su, G., Qiu, S., and Tian, W. (2011). Analysis of CHF in saturated forced convective boiling on a heated surface with impinging jets using artificial neural network and genetic algorithm. Nuclear engineering and design, 241(9), 3945-3951.

[221] Zaferanlouei, S., Rostamifard, D., and Setayeshi, S. (2010). Prediction of critical heat flux using ANFIS. Annals of Nuclear Energy, 37(6), 813-821.

[222] Chen, R. H., Su, G. H., Qiu, S. Z., and Fukuda, K. (2010). Prediction of CHF in concentric-tube open thermosiphon using artificial neural network and genetic algorithm. Heat and mass transfer, 46(3), 345-353.

[223] Wei, H., Su, G. H., Qiu, S. Z., Ni, W., and Yang, X. (2010). Applications of genetic neural network for prediction of critical heat flux. International journal of thermal sciences, 49(1), 143-152.

[224] Wei, H. M., Su, G. H., Tian, W. X., Qiu, S. Z., Ni, W. F., and Yang, X. B. (2010). Study on dry out point by wavelet and GNN. Applied thermal engineering, 30(6-7), 664-672.

[225] Moon, S. K., and Chang, S. H. (1994). Classification and prediction of the critical heat flux using fuzzy theory and artificial neural networks. Nuclear engineering and design, 150(1), 151-161.

[226] Guanghui, S., Morita, K., Fukuda, K., Pidduck, M., Dounan, J., and Miettinen, J. (2003). Analysis of the critical heat flux in round vertical tubes under low pressure and flow oscillation conditions. Applications of artificial neural network. Nuclear Engineering and Design, 220(1), 17-35.

[227] del Castillo, A. Á., Santoyo, E., and García-Valladares, O. (2012). A new void fraction correlation inferred from artificial neural networks for modeling two-phase flows in geothermal wells. Computers & Geosciences, 41, 25-39.

[228] Zhang, W., Hibiki, T., and Mishima, K. (2010). Correlations of two-phase frictional pressure drop and void fraction in mini-channel. International Journal of Heat and Mass Transfer, 53(1-3), 453-465.

[229] Malayeri, M. R., Müller-Steinhagen, H., and Smith, J. M. (2003). Neural network analysis of void fraction in air/water two-phase flows at elevated temperatures. Chemical Engineering and Processing: Process Intensification, 42(8-9), 587-597.

[230] Shaban, H., and Tavoularis, S. (2014). Identification of flow regime in vertical upward air–water pipe flow using differential pressure signals and elastic maps. International Journal of Multiphase Flow, 61, 62-72.

[231] Inan, C., Gonul, T., and Tanes, M. Y. (2003). X-ray investigation of a domestic refrigerator. Observations at 25 C ambient temperature. International journal of Refrigeration, 26(2), 205-213.

[232] Tjugum, S. A., Johansen, G. A., and Holstad, M. B. (2001). The use of gamma radiation in fluid flow measurements. Radiation Physics and Chemistry, 61(3-6), 797-798.

[233] Chaouki, J., Larachi, F., and Dudukovic, M. P. (Eds.). (1997). Non-invasive monitoring of multiphase flows. Elsevier.

[234] Mi, Y., Ishii, M., and Tsoukalas, L. H. (1998). Vertical two-phase flow identification using advanced instrumentation and neural networks. Nuclear engineering and design, 184(2-3), 409-420.

[235] Mi, Y., Ishii, M., and Tsoukalas, L. H. (2001). Flow regime identification methodology with neural networks and two-phase flow models. Nuclear engineering and design, 204(1-3), 87-100.

[236] Tambouratzis, T., and &Pázsit, I. (2009). Non-invasive on-line two-phase flow regime identification employing artificial neural networks. Annals of Nuclear Energy, 36(4), 464-469.

[237] Tambouratzis, T., and Pàzsit, I. (2010). A general regression artificial neural network for two-phase flow regime identification. Annals of Nuclear Energy, 37(5), 672-680.

[238] Timung, S., and Mandal, T. K. (2013). Prediction of flow pattern of gas–liquid flow through circular microchannel using probabilistic neural network. Applied Soft Computing, 13(4), 1674-1685.

[239] PEREIRA, C. M. D. N. A., SALGADO, C. M., Schirru, R., and BRANDÃO, L. E. B. (2010). Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks.

[240] Demir, H., Ağra, Ö., and Atayılmaz, Ş. Ö. (2009). Generalized neural network model of alternative refrigerant (R600a) inside a smooth tube. International Communications in Heat and Mass Transfer, 36(7), 744-749.

[241] Balcilar, M., Dalkilic, A. S., and Wongwises, S. (2011). Artificial neural network techniques for the determination of condensation heat transfer characteristics during downward annular flow of R134a inside a vertical smooth tube. International Communications in Heat and Mass Transfer, 38(1), 75-84.

[242] Balcilar, M., Dalkilic, A. S., Agra, O., Atayilmaz, S. O., and Wongwises, S. (2012). A correlation development for predicting the pressure drop of various refrigerants during condensation and evaporation in horizontal smooth and micro-fin tubes. International communications in heat and mass transfer, 39(7), 937-944.

[243] Ermis, K., Erek, A., and Dincer, I. (2007). Heat transfer analysis of phase change process in a finned-tube thermal energy storage system using artificial neural network. International Journal of Heat and Mass Transfer, 50(15-16), 3163-3175.

[244] Bittanti, S., and Piroddi, L. (1997). Nonlinear identification and control of a heat exchanger: a neural network approach. Journal of the Franklin Institute, 334(1), 135-153.

[245] Riverol, C., and Napolitano, V. (2000). Use of neural networks as a tuning method for an adaptive PID. Chemical Engineering Research and Design, 8(78), 1115-1119.

[246] Dı´az, G., Sen, M., Yang, K. T., and McClain, R. L. (2001). Adaptive neuro control of heat exchangers. J. Heat Transfer, 123(3), 556-562.

[247] Díaz, G., Sen, M., Yang, K. T., and McClain, R. L. (2001). Dynamic prediction and control of heat exchangers using artificial neural networks. International Journal of Heat and Mass Transfer, 44(9), 1671-1679.

[248] Varshney, K., and Panigrahi, P. K. (2005). Artificial neural network control of a heat exchanger in a closed flow air circuit. Applied Soft Computing, 5(4), 441-465.

[249] Abbassi, A., and Bahar, L. (2005). Application of neural network for the modeling and control of evaporative condenser cooling load. Applied Thermal Engineering, 25(17-18), 3176-3186.

[250] Nanayakkara, V. K., Ikegami, Y., and Uehara, H. (2002). Evolutionary design of dynamic neural networks for evaporator control. International journal of refrigeration, 25(6), 813-826.

[251] Vasičkaninová, A., Bakošová, M., Mészáros, A., and Klemeš, J. J. (2011). Neural network predictive control of a heat exchanger. Applied Thermal Engineering, 31(13), 2094-2100.

[252] Hu, Q., So, A. T., Tse, W. L., and Ren, Q. (2005). Development of ANN-based models to predict the static response and dynamic response of a heat exchanger in a real MVAC system. In Journal of Physics: Conference Series (Vol. 23, No. 1, p. 013). IOP Publishing.

[253] Li, N., Xia, L., Shiming, D., Xu, X., and Chan, M. Y. (2012). Dynamic modeling and control of a direct expansion air conditioning system using artificial neural network. Applied Energy, 91(1), 290-300.

[254] Li, N., Xia, L., Shiming, D., Xu, X., and Chan, M. Y. (2013). On-line adaptive control of a direct expansion air conditioning system using artificial neural network. Applied Thermal Engineering, 53(1), 96-107.

[255] Jahedi, G., and Ardehali, M. M. (2012). Wavelet based artificial neural network applied for energy efficiency enhancement of decoupled HVAC system. Energy Conversion and Management, 54(1), 47-56.

[256] Gang, W., Wang, J., and Wang, S. (2014). Performance analysis of hybrid ground source heat pump systems based on ANN predictive control. Applied energy, 136, 1138-1144.

[257] Kumari, A., Das, S. K., and Srivastava, P. K. (2014). A neural network model for quantitative prediction of oxide scale in water walls of an operating Indian coal fired boiler. Research and Review in Electrochemistry, 5, 155-168.

[258] Soleimani, R., Shoushtari, N. A., Mirza, B., and Salahi, A. (2013). Experimental investigation, modeling and optimization of membrane separation using artificial neural network and multi-objective optimization using genetic algorithm. Chemical Engineering Research and Design, 91(5), 883-903.

[259] Davoudi, E., and Vaferi, B. (2018). Applying artificial neural networks for systematic estimation of degree of fouling in heat exchangers. Chemical Engineering Research and Design, 130, 138-153.

[260] Huminic, G., and Huminic, A. (2012). Application of nanofluids in heat exchangers: A review. Renewable and Sustainable Energy Reviews, 16(8), 5625-5638.

[261] Cong, T., Su, G., Qiu, S., and Tian, W. (2013). Applications of ANNs in flow and heat transfer problems in nuclear engineering: a review work. Progress in Nuclear Energy, 62, 54-71.

[262] Haykin, S., and Principe, J. (1998). Making sense of a complex world [chaotic events modeling]. IEEE Signal Processing Magazine, 15(3), 66-81.

[263] Mellit, A., and Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. Progress in energy and combustion science, 34(5), 574-632.

[264] Kalogirou, S. A. (2003). Artificial intelligence for the modeling and control of combustion processes: a review. Progress in energy and combustion science, 29(6), 515-566.

[265] Kalogirou, S. A. (2000). Applications of artificial neural-networks for energy systems. Applied energy, 67(1-2), 17-35.

[266] Kalogirou, S. A. (2001). Artificial neural networks in renewable energy systems applications: a review. Renewable and sustainable energy reviews, 5(4), 373-401.

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

[268] Boser, B. E., Guyon, I. M., and Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In Proceedings of the fifth annual workshop on Computational learning theory (pp. 144-152).

[269] Cortes, C., and Vapnik, V. (1995). Support-vector networks. Machine learning, 20(3), 273-297.

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

[271] Abdollahi, S., Pourghasemi, H. R., Ghanbarian, G. A., and Safaeian, R. (2019). Prioritization of effective factors in the occurrence of land subsidence and its susceptibility mapping using an SVM model and their different kernel functions. Bulletin of Engineering Geology and the Environment, 78(6), 4017-4034.

[272] Yan, K., and Shi, C. (2010). Prediction of elastic modulus of normal and high strength concrete by support vector machine. Construction and building materials, 24(8), 1479-1485.

[273] Llinares Fontdevila, A. (2004). Fouling of a double pipe heat exchanger (Doctoral dissertation, Dublin City University).

[274] Garson, D.G. (1991). Interpreting neural network connection weights.

[275] Eguía, E., Vidart, T. F., Bezanilla, J. A., Amieva, J. J., Otero, P. M., Giron, M. A., and Ruiz, M. (1970). Elimination of biofouling in heat exchangers-condensers by different chemical methods. WIT Transactions on The Built Environment, 39.

[276] Zubair, S. M., Sheikh, A. K., Younas, M., and Budair, M. O. (2000). A risk based heat exchanger analysis subject to fouling: Part I: Performance evaluation. Energy, 25(5), 427-443.

[277] Casanueva, J. F., Sánchez, J., García-Morales, J. L., Casanueva-Robles, T., López, J. A., Portela, J. R., and Sales, D. (2003). Portable pilot plant for evaluating marine biofouling growth and control in heat exchangers-condensers. Water Science and Technology, 47(5), 99-104.

[278] Qureshi, B. A., and Zubair, S. M. (2005). The impact of fouling on performance evaluation of evaporative coolers and condensers. International journal of energy research, 29(14), 1313-1330.

[279] Nebot, E., Casanueva, J. F., Casanueva, T., and Sales, D. (2007). Model for fouling deposition on power plant steam condensers cooled with seawater: Effect of water velocity and tube material. International Journal of Heat and Mass Transfer, 50(17-18), 3351-3358.

[280] Walker, M. E., Safari, I., Theregowda, R. B., Hsieh, M. K., Abbasian, J., Arastoopour, H., and Miller, D. C. (2012). Economic impact of condenser fouling in existing thermoelectric power plants. Energy, 44(1), 429-437.

[281] Zhang, Z. B., Liu, Y., and Cao, L. H. (2019). A novel method for calculating effective thermal conductivity of particulate fouling. Thermal Science, (00), 308-308.

[282] Rezrazi, A., Hanini, S., and Laidi, M. (2016). An optimisation methodology of artificial neural network models for predicting solar radiation: a case study. Theoretical and applied climatology, 123(3-4), 769-783.

[283] Laidi, M., and Hanini, S. (2013). Optimal solar COP prediction of a solar-assisted adsorption refrigeration system working with activated carbon/methanol as working pairs using direct and inverse artificial neural network. International Journal of Refrigeration, 36(1), 247-257.

[284] Abdallahelhadj. A., Laidi, M., Si-Moussa, C., and Hanini, S. (2017). Novel approach for estimating solubility of solid drugs in supercritical carbon dioxide and critical properties using direct and inverse artificial neural network (ANN). Neural Computing and Applications, 28(1), 87-99.

[285] Melzi, N., Khaouane, L., Ammi, Y., Hanini, S., Laidi, M., and Zentou, H. (2019). Comparative Study of Predicting the Molecular Diffusion Coefficient for Polar and Non-polar Binary Gas Using Neural Networks and Multiple Linear Regressions. Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske, 68(11-12), 573-582.

[286] Jradi, R., Marvillet, C., and Jeday, M. R. (2020). Modeling and comparative study of heat exchangers fouling in phosphoric acid concentration plant using experimental data. Heat and Mass Transfer, 56(9), 2653-2666.

[287] Hykin, S. (1999). Neural networks: a comprehensive foundation. Printice-hall. Inc., New Jersey, 120-134.

[288] Dreyfus, G. (2005). Neural networks: methodology and applications. Springer Science & Business Media.

[289] Engelbrecht, A. P. (2007). Computational intelligence: an introduction. John Wiley & Sons.

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

[291] Vogl, T. P., Mangis, J. K., Rigler, A. K., Zink, W. T., and Alkon, D. L. (1988). Accelerating the convergence of the back-propagation method. Biological cybernetics, 59(4), 257-263.

[292] Rafiq, M. Y., Bugmann, G., and Easterbrook, D. J. (2001). Neural network design for engineering applications. Computers & Structures, 79(17), 1541-1552.

[293] Ararem, A., Bouzidi, A., Mohamedi, B., and Bouras, O. (2014). Modeling of fixed-bed adsorption of Cs^{+} and Sr^{2+} onto clay–iron oxide composite using artificial neural network and constant–pattern wave approach. Journal of Radioanalytical and Nuclear Chemistry, 301(3), 881-887.

[294] Mohamedi, B., Hanini, S., Ararem, A., and Mellel, N. (2015). Simulation of nucleate boiling under ANSYS-FLUENT code by using RPI model coupling with artificial neural networks. Nuclear Science and Techniques, 26(4), 40601-040601.

[295] Soleimani, R., Dehaghani, A. H. S., Shoushtari, N. A., Yaghoubi, P., and Bahadori, A. (2018). Toward an intelligent approach for predicting surface tension of binary mixtures containing ionic liquids. Korean Journal of Chemical Engineering, 35(7), 1556-1569.

[296] Ross, T. (1996). Indices for performance evaluation of predictive models in food microbiology. Journal of applied bacteriology, 81(5), 501-508.

[297] Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1985). Learning internal representations by error propagation. California Univ San Diego La Jolla Inst for Cognitive Science.

[298] Hamzaoui, Y. E., Hernández, J. A., Silva-Martínez, S., Bassam, A., Álvarez, A., and Lizama-Bahena, C. (2011). Optimal performance of COD removal during aqueous treatment of alazine and gesaprim commercial herbicides by direct and inverse neural network. Desalination, 277(1-3), 325-337.

[299] Hattab, N., and Motelica-Heino, M. (2014). Application of an inverse neural network model for the identification of optimal amendment to reduce copper toxicity in phytoremediated contaminated soils. Journal of Geochemical Exploration, 136, 14-23.

[300] Hernández, J. A. (2009). Optimum operating conditions for heat and mass transfer in foodstuffs drying by means of neural network inverse. Food Control, 20(4), 435-438.

[301] Cortés, O., Urquiza, G., and Hernández, J. A. (2009). Optimization of operating conditions for compressor performance by means of neural network inverse. Applied Energy, 86(11), 2487-2493.

[302] Kashani, M. N., Aminian, J., Shahhosseini, S., and Farrokhi, M. (2012). Dynamic crude oil fouling prediction in industrial preheaters using optimized ANN based moving window technique. Chemical Engineering Research and Design, 90(7), 938-949.

[303] Aminian, J., and Shahhosseini, S. (2009). Neuro-based formulation to predict fouling threshold in crude preheaters. International Communications in Heat and Mass Transfer, 36(5), 525-531.

[304] Rani, G. J., Rani, G. S., and Praveen, A. (2020). Nano fluids effect on crossflow heat exchanger characteristics–Review. Materials Today: Proceedings.

[305] Awais, M., and Bhuiyan, A. A. (2019). Recent advancements in impedance of fouling resistance and particulate depositions in heat exchangers. International Journal of Heat and Mass Transfer, 141, 580-603.

[306] Williamson, R., Newson, I., Bott, T. R., The deposition of hematite particles from flowing water. Can. J. Chem. Eng., 66, p. 51 (1988).

[307] Grandgeorge, S., Jallut, C., Thonon, B., Particulate fouling of corrugated plate heat exchangers. Global kinetic and equilibrium studies. Chem. Eng. Sci., 53, (17), p. 3051 (1998).

[308] Peyghambarzadeh, S. M., Vatani, A., and Jamialahmadi, M. (2012). Experimental study of micro-particle fouling under forced convective heat transfer. Brazilian Journal of Chemical Engineering, 29(4), 713-724.

[309] Peyghambarzadeh, S. M., Vatani, A., and Jamialahmadi, M. (2013). Influences of bubble formation on different types of heat exchanger fouling. Applied thermal engineering, 50(1), 848-856.

[310] Nikkhah, V., Sarafraz, M. M., Hormozi, F., and Peyghambarzadeh, S. M. (2015). Particulate fouling of CuO–water nanofluid at isothermal diffusive condition inside the conventional heat exchanger-experimental and modeling. Experimental Thermal and Fluid Science, 60, 83-95.

[311] Tang, K. H., Kazi, S. N., Amiri, A., Habali, A. F., Bakar, M. A., Chew, B. T., and Khan, G. (2017). Calcium carbonate fouling on double-pipe heat exchanger with different heat exchanging surfaces. Powder Technology, 315, 216-226.

[312] Wang, S., Xu, Z., and Wang, J. (2019). Fouling characteristics of MgO particles under subcooled flow boiling. Journal of Mechanical Science and Technology, 33(3), 1399-1407.

[313] Wang, J., Xu, Z., Han, Z., and Zhao, Y. (2018). Effect of heat flux and inlet temperature on the fouling characteristics of nanoparticles. Chinese Journal of Chemical Engineering, 26(3), 623-630.

[314] Sarafraz, M. M., and Hormozi, F. (2014). Convective boiling and particulate fouling of stabilized CuO-ethylene glycol nanofluids inside the annular heat exchanger. International Communications in Heat and Mass Transfer, 53, 116-123.

[315] Kiani, M. K. D., Ghobadian, B., Tavakoli, T., Nikbakht, A. M., and Najafi, G. (2010). Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol-gasoline blends. Energy, 35(1), 65-69.

[316] Mohanraj, M., Jayaraj, S., and Muraleedharan, C. (2012). Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—a review. Renewable and Sustainable Energy Reviews, 16(2), 1340-1358.

[317] Bouali, A., Hanini, S., Mohammedi, B., and Boumahdi, M. (2020). Using artificial neural network for predicting heat transfer coefficient during flow boiling in an inclined channel. Thermal Science, (00), 238-238.

[318] Benimam, H., Moussa, C. S., Hentabli, M., Hanini, S., and Laidi, M. (2020). 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.

[319] Tang, S. Z., Li, M. J., Wang, F. L., He, Y. L., and Tao, W. Q. (2020). Fouling potential prediction and multi-objective optimization of a flue gas heat exchanger using neural networks and genetic algorithms. International Journal of Heat and Mass Transfer, 152, 119488.

[320] Kukulka, D. J., Devgun, M. (2007). Fluid temperature and velocity effect on fouling. Applied Thermal Engineering, 27(16), 2732-2744.

[321] Setoodeh, H., Keshavarz, A., Ghasemian, A., Nasouhi, A. (2015). Subcooled flow boiling of alumina/water nanofluid in a channel with a hot spot: An experimental study. Applied Thermal Engineering, 90, 384-394.

[322] Prodanovic, V., Fraser, D., Salcudean, M. (2002). Bubble behavior in subcooled flow boiling of water at low pressures and low flow rates. International Journal of Multiphase Flow, 28(1), 1-19.

[323] Al-Janabi, A., Malayeri, M. R., Müller-Steinhagen, H. (2011). Minimization of $CaSO_4$ deposition through surface modification. Heat transfer engineering, 32(3-4), 291-299.

[324] Ghahdarijani, A. M., Hormozi, F., Asl, A. H. (2017). Convective heat transfer and pressure drop study on nanofluids in double-walled reactor by developing an optimal multilayer perceptron artificial neural network. International Communications in Heat and Mass Transfer, 84, 11-19.

[325] Zhan, F., Tang, J., Ding, G., Zhuang, D. (2016). Experimental investigation on particle deposition characteristics of wavy fin-and-tube heat exchangers. Applied Thermal Engineering, 99, 1039-104

[326] Ojaniemi, U., Riihimäki, M., Manninen, M., Pättikangas, T. (2012). Wall function model for particulate fouling applying XDLVO theory. Chemical engineering science, 84, 57-69.