

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

UNIVERSITÉ BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY



جامعة بادجي مختار – عنابة

Faculté : technologie
Département : Génie des procédés
Domaine : Science et technologie
Filière : Génie des procédés
Spécialité : Génie Chimique

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème:

Modélisation des paramètres lié au dessalement d'eau de mer

Présenté par : *Boukeffa Mohamed Aymen / Hemissi Yazid*

Encadrant : *Dr ROUBEHIE FISSA*

MAB

UBMA

Jury de Soutenance :

Pr DERADJI	Professeur	UBMA	Président
Dr ROUBEHIE FISSA	MAB	UBMA	Encadrant
Dr LAKROUT	MAB	UBMA	Examineur

Année Universitaire : 2023/2024

Remerciements

Je remercie dieu le tout puissant pour la volonté, la santé et la patience qu'il m'a accordé durant tous ces longues années d'études et qui me a permis d'arriver là où je suis. Je remercie très vivement mon encadreur Dr M.Roubehie fissa. je vous exprime mes vives reconnaissances et immense gratitude pour votre aide précieuse et claire lors de l'élaboration de ce travail. Je voudrai aussi exprimer mes remerciements à mes professeurs du département de génie des procédés qui ont contribués à ma formation. J'en profite ici pour remercier tous les membres de ma famille, en tête mes parents qui m'ont apporté beaucoup de soutien durant toute ma scolarité. Mes derniers remerciements, vont à tous qui ont contribué de près ou de loin pour l'aboutissement de ce travail

Dédicace

Avant tous je dis « **ALHAMDYOU LI ALLAH** »

Qui m'a aidée et donnée l'effort, la volonté et le Courage de réaliser et permis de présenter mon Modeste travail qui est les résultats de langues années d'étude A mes très chers parents A mon très cher père « Abd el karim » qui je dois le plus grand respect, qui a toujours fait preuve de générosité et de sacrifice, a qui mes études faisaient les grandes joies de sa vie et a je dis merci beaucoup.

A ma très chère mère « Nadia » vous qui m'a faite qui avez forgée qui décidez de mon destin, qui avez essayé mes pleurs, éclairée mes veillées, encouragée mes efforts vous qui vous êtes sacrifiés pour que je dis merci beaucoup.

A mes frères et A mes sœurs : Billel, Sara, Ines, Asma.

A mes chers amis : Badri, Rakib, Asma, Souhaila

Boukeffa mohamed aymen

Dédicace

*J'offre ce modeste travail : A ceux qui m'ont mis au monde, que je respecte et qui m'honorent,
ma mère et mon père.*

A mes chers frères et sœurs, A tous mes amis, ils sont nombreux ils se reconnaîtront sûrement

A tous ceux qui m'ont encouragé tout au long de mes études.

A tous mes professeurs de l'université Badji moukhtar Annaba.

Hemissi Yazid

ملخص: نمذجة عمليات التحلية الهجينة باستخدام الشبكات العصبية الاصطناعية

الهدف الرئيسي من هذه الدراسة هو نمذجة عمليات التحلية الهجينة التي تجمع بين تقنيات التناضح النانوي (NF) ، والتناضح العكسي (OI) ، والتقطير متعدد المراحل (MSF) تم إجراء هذه الدراسة لتطوير نماذج رياضية من نوع الشبكات العصبية الاصطناعية (RNA) للتنبؤ بالعديد من المعايير الرئيسية لعملية التحلية. تم استخدام قاعدة بيانات تحتوي على 60 تجربة، تمثل معايير مثل الوقت (t)، الضغط (P)، درجة الحرارة (T)، معدل التدفق الداخل (Qin)، توصيلية المياه الداخلة (Cin)، معدل تحويل المياه النفاذة (TCp)، معدل تدفق المياه النفاذة (Qp)، وتوصيلية المياه النفاذة (Cp). تم معالجة البيانات مسبقاً لاختيار المدخلات ذات الصلة، وحساب الارتباطات بين المتغيرات.

تم تقسيم مجموعة البيانات عشوائياً إلى ثلاث مجموعات: الأولى تحتوي على 70٪ لمرحلة التعلم و30٪ لمرحلة الاختبار، والثانية تحتوي على 80٪ للتعلم و20٪ للاختبار، وأخيراً الثالثة تحتوي على 90٪ للتعلم و10٪ للاختبار. تم تطبيق خوارزمية BFGS لتدريب الشبكات العصبية الاصطناعية. كانت أفضل بنية للنماذج التي تم الحصول عليها هي: "01-08-03" لمعدل تحويل المياه النفاذة (TCp)، "04-10-01" لمعدل تدفق المياه النفاذة (Qp)، و"01-17-04" لتوصيلية المياه النفاذة (Cp). كانت النتائج مشجعة للغاية، وأكدت القيم العالية لمعامل التحديد (R²) التي تجاوزت 0.90 للنماذج الثلاثة، والقيم المنخفضة لمتوسط الخطأ التربيعي (EQM). أظهرت نتائج تحليل الحساسية بوضوح أهمية معايير المدخلات المستخدمة في كل نموذج. يمكن تطبيق هذا النهج الحسابي في مجال الهندسة البيئية أو في مجالات أخرى ذات صلة لتحديد دقيق لمعاملات عمليات التحلية باستخدام معايير مرتبطة بالهياكل الكيميائية والظواهر الفيزيائية.

الكلمات المفتاحية: نمذجة العمليات، التحلية الهجينة، الشبكات العصبية الاصطناعية، معايير التحلية، معالجة البيانات مسبقاً، تحليل الارتباط.

Résumé : Modélisation des processus de dessalement hybride utilisant les réseaux de neurones artificiels

L'objectif principal de cette étude est la modélisation des processus de dessalement hybride combinant les techniques de Nanofiltration (NF), d'Osiose Inverse (OI), et de Distillation Multi-Étages (MSF). Cette recherche a été entreprise pour développer des modèles mathématiques de type Réseau de Neurones Artificiels (RNA) afin de prédire divers paramètres clés du processus de dessalement. Une base de données de 60 expériences, représentant des paramètres tels que le temps (t), la pression (P), la température (T), le débit d'entrée (Qin), la conductivité de l'eau en entrée (Cin), le taux de conversion de perméat (TCp), le débit de perméat (Qp) et la conductivité de l'eau perméat (Cp) a été utilisée. Les données ont été prétraitées pour sélectionner les entrées pertinentes, et les corrélations entre les variables ont été calculées.

L'ensemble de données a été divisé au hasard en trois partitions : la première contient 70% pour la phase d'apprentissage et 30% pour la phase de test, la deuxième de la même façon avec 80% pour l'apprentissage et 20% pour le test, et finalement la troisième avec 90% pour l'apprentissage et 10% pour le test. L'algorithme BFGS a été appliqué pour entraîner les RNA. L'architecture des meilleurs modèles obtenus était : "03-08-01" pour le taux de conversion de perméat (TCp), "04-10-01" pour le débit de perméat (Qp), et "04-17-01" pour la conductivité de l'eau perméat (Cp). Les résultats étaient très encourageants, confirmés par les valeurs élevées du coefficient de détermination (R²) qui dépassent 0.90 pour les trois modèles, et les faibles valeurs de l'erreur quadratique moyenne (EQM). Les résultats de l'analyse de sensibilité ont clairement montré l'importance des paramètres d'entrée utilisés dans chaque modèle. Cette approche computationnelle peut être appliquée dans le domaine de l'ingénierie environnementale ou dans d'autres domaines connexes pour une détermination précise des paramètres des processus de dessalement en utilisant des paramètres liés aux structures chimiques et aux phénomènes physiques.

Mots-clés : Modélisation des processus, dessalement hybride, réseaux de neurones artificiels, paramètres de dessalement, prétraitement des données, analyse de corrélation

Abstract: Modeling Hybrid Desalination Processes Using Artificial Neural Networks

The main objective of this study is to model hybrid desalination processes combining Nanofiltration (NF), Reverse Osmosis (RO), and Multi-Stage Distillation (MSF) techniques. This research was undertaken to develop Artificial Neural Network (ANN) mathematical models to predict various key parameters of the desalination process. A database of 60 experiments, representing parameters such as time (t), pressure (P), temperature (T), inlet flow rate (Qin), inlet water conductivity (Cin), permeate conversion rate (TCp), permeate flow rate (Qp) and permeate water conductivity (Cp) was used. The data were pre-processed to select relevant inputs, and correlations between variables were calculated.

The dataset was randomly divided into three partitions: the first containing 70% for the learning phase and 30% for the testing phase, the second in the same way with 80% for learning and 20% for testing, and finally the third with 90% for learning and 10% for testing. The BFGS algorithm was applied to train the RNAs. The architecture of the best models obtained was: "03-08-01" for permeate conversion rate (TCp), "04-10-01" for permeate flow rate (Qp), and "04-17-01" for permeate water conductivity (Cp). The results were very encouraging, confirmed by the high values of the coefficient of determination (R²), which exceeded 0.90 for all three models, and the low values of the root mean square error (RMSE). The results of the sensitivity analysis clearly showed the importance of the input parameters used in each model. This computational approach can be applied in the field of environmental engineering or other related fields for accurate determination of desalination process parameters using parameters related to chemical structures and physical phenomena.

Keywords: Process modelling, hybrid desalination, artificial neural networks, desalination parameters, data pre-processing, correlation analysis.

Table des matières

Introduction générale	1
Chapitre I: Traitement des eaux de mer et notion de portabilité	
I.1. Généralité sur les eaux de mer	4
I.1.1. Définition.....	4
I.1.2. Principales compositions de l'eau de mer.....	4
I.1.2.2. Matières organiques.....	7
I.1.2.3. Les technologies de dessalement.....	7
I.2.1 Procédé thermique	8
I.2.1.1 Le procédé de distillation par détente successives (Multi Stage Flash MSF)	8
I.2.1.2 Le procédé de distillation à multiples effets (Multi-Effects Distillation MED)	9
I.2.1.3. Multi-effets avec compression de vapeur	10
I.2.2. Filtration membranaire.....	11
I.2.2.1. Les techniques membranaires à gradient de pression.....	11
□ I.2.2.1.4. L'osmose inverse	12
I.2.2.2. Technique membranaire à gradient de potentiel électrique	13
I.3. Dessalement par procédé hybride Nanofiltration/Osmose inverse	14
I.4. Procédé de prétraitement de l'osmose inverse	15
I.5. Conclusion	15
Chapitre II : Technique de modélisation (réseau de neurone)	
II.1. Introduction	18
II.2. Généralités sur la modélisation.....	18
II.2.1. Le modèle mathématique :	18
II.2.2. Définitions.....	19
II.3. Réseaux de Neurone.....	19
II.3.1. Aperçu général	19
II.3.4. Les Fondements du Modèle Mathématique	22
II.3.6 Types de Réseaux de Neurones.....	25
II.3.7. Fonctions d'Activation:	26
II.3.8. Sélection des Variables d'Entrée	27
II.3.9. Complexité du Réseau de Neurones.....	28

II.3.10.Apprentissage du Réseau	28
II.3.11. La Fonction d'Erreur	30
II.3.12. L'Algorithme d'Apprentissage :	32
II.3.14. Données de Validation	34
II.3.15. Transformation et Traitement a Posteriori des Données.....	35
III.3.17 Conclusion	36
Chapitre III : Modélisation des paramètre liée aux dessalement d'eau de mer par RNA	
III.1. Introduction	38
III.2. Matériels et méthodes	39
III.2.1. Outils informatiques utilisés	39
III.2.2. Méthodologie générale de la modélisation	40
III.2.2.1. Collection et préparation de la base des données	41
III.2.2.2. Traitement et organisation des données	42
III.2.2.3. Élaboration du modèle RNA	42
III.2.2.4. Analyses statistiques et calculs des erreurs des meilleurs modèles développés ...	44
III.2.2.5. Mesure de la contribution relative des entrées des modèles RNA développées	45
III.3. Résultats et discussions	47
III.3.1. Résultats d'organisation de la base et sélection des entres pertinentes	47
III.3.2. Résultats d'exécution des modèles neuronales des paramètres liés aux dessalement de l'eau de mer	48
III.3.3. Architectures des meilleurs modèles de RNA obtenus	58
III.3.4. Application des expressions mathématiques des modèles de RNA obtenus	60
III.3.4. Estimation de la performance des résultats d'estimation issus des modèles RNA développés	64
III.3.4.1. Comparaison graphique entre les valeurs expérimentales et calculées à partir des modèles RNA	64
III.3.5. Calculs des paramètres de performance et analyse statistique des modèles de type RNA obtenus	68
III.3.6. Analyse de sensibilité des Paramètres dans chaque modèle de RNA par la méthode de poids	69
III.3.7. Interprétation et classification des contributions selon la (VCM)	72
III.4. Conclusion.....	72
Conclusion générale.....	80

Liste des tableaux

Chapitre I. les eaux de mer et notion de potabilité		
Tableau I.1	Concentration usuelles des principaux constituants inorganiques de l'eau de mer	6

Chapitre III. Modélisation des paramètres liée aux dessalements d'eau de mer par RNA		
Tableau III.1	Paramètres quantitatives et qualitatives de la base des données	42
Tableau III.2	Coefficients de corrélation des paramètres d'entrées et de sorties	48
Tableau III.3	Résultats d'exécutions des modèles de RNA pour le taux convention du perméat TC_P (%)	50
Tableau III.4	Résultats d'exécutions des modèles de RNA pour le débit du perméat Q_P (m^3/h)	51
Tableau III.5	Résultats d'exécutions des modèles de RNA pour la conductivité du perméat C_P ($\mu S/cm$)	52
Tableau III.6	Architectures des meilleurs modèles de RNA obtenus pour chaque paramètre	59
Tableau III.7	Fonctions d'activation apparues dans cette étude	60
Tableau III.8	Poids et biais du meilleur modèle de RNA pour TC_P (3-8-1)	62
Tableau III.9	Poids et biais du meilleur modèle de RNA pour Q_P (4-10-1)	63
Tableau III.10	Poids et biais du meilleur modèle RQSP-RNA pour C_P (4-17-1)	63
Tableau III.11	Paramètres statistiques des meilleurs modèles de RNA pour les trois propriétés	68

Annexes

Annexe A.

Tableau A.1

La base de données des paramètres liés au dessalement d'eau de mer

87

Liste des figures

Chapitre I. les eaux de mer et notion de potabilité		
Figure I.1	Capacité totale installations de dessalement le monde	7
Figure I.2	Schéma de principe de la distillation multi stage flash distillation	9
Figure I.3	Schéma de principe de la distillation Multiple Effet (MED)	10
Figure I.4	Compression mécanique de vapeur à un seul effet	11
Figure I.5	Schéma de principe d'une unité d'osmose inverse	13
Figure I.6	Principe de l'électrodialyse conventionnelle	14

Chapitre II. Technique de medolisation (réseau de neurone)		
Figure II.1	Neurone biologique schématisé	22
Figure II.2	Modèle à un seul neurone	23
Figure II.3	Schéma d'un réseau de neurones PMC totalement connecté à trois entrées, quatre unités cachées (neurones), et trois sorties	25
Figure II.4	Différentes fonction d'activation : (a) Linéaire. (b) Sigmoide et (c) Tangente hyperbolique	27
Figure II.5	Schéma de l'apprentissage d'un réseau de neurones avec interruption prématurée	34

Chapitre III. Modélisation des paramètres liée aux dessalements d'eau de mer par RNA		
Figure III.1	Capture d'écran des logiciels utilisés dans cette étude : MATLAB, STATISTICA, et Microsoft Office Excel	40
Figure III.2	Organigramme générale décrit la méthodologie de développement suivie dans ce travail.	41
Figure III.3	Représentation graphique des divisions de la base des données	43
Figure III.4	Capture d'écran pour le choix des fonctions d'activation sur STATISTICA	44
Figure III.5	Organigramme illustrant l'analyse de sensibilité par la méthode de la partition des poids (méthode de poids)	46
Figure III.6	Evaluation des corrélations des modèles liés au paramètre TC_P selon divisions et itérations	53
Figure III.7	Evaluation des corrélations des modèles liés au paramètre Q_P selon divisions et itérations	55
Figure III.8	Evaluation des corrélations des modèles liés au paramètre C_P selon divisions et itérations	57
Figure III.9	Représentation schématique d'un réseau du modèle de type RNA	60
Figure III.10	Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de la conversion de perméat TC_p pour la base des données entière	65
Figure III.11	Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de la conversion de perméat Q_p pour la base des données entière	66
Figure III.12	Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de la conductivité de l'eau perméat C_p pour la base des données entière	67
Figure III.13	Contributions relatives des paramètres pertinents d'entrée pour le modèle de RNA de la conversion de perméat TC_P .	70
Figure III.14	Contributions relatives des paramètres pertinents d'entrée pour le modèle de RNA de la conversion de perméat Q_P .	71

Figure III.15	Contributions relatives des Paramètres pertinents d'entrée pour le modèle de RNA de la conductivité du perméat C_P	71
----------------------	--	----

Chapitre I

les eaux de mer et notion de potabilité

Introduction générale

Aujourd'hui, en Algérie comme dans de nombreuses régions du monde, les ressources en eau douce pour la production d'eau potable sont insuffisantes vis-à-vis de la croissance démographique ou de la production industrielle. Par conséquent, des solutions telles que la réutilisation d'eau et le dessalement d'eau de mer, deviennent des solutions clés, répondant en outre aux exigences du développement durable. Le recours aux techniques membranaires est plus en plus important pour résoudre le problème d'approvisionnement en eau destinée à la consommation humaine, dont leurs techniques deviennent de moins en moins coûteuses. **(Tansakul ,2019) .**

La technologie concurrente dominante est l'osmose inverse (OI), ayant d'une capacité de production mondiale allant de 600 à 2000 m³/j (Qasim et al.2019). Cette technique nécessite uniquement de l'électricité, tandis que le dessalement thermique (MSF, MED) nécessite à la fois de l'électricité et de l'énergie thermique, ainsi que OI consomme moins d'énergie que MSF et MED **(El-Ghonemy 2012).**

L'efficacité des membranes OI est souvent limitée c'est pourquoi L'intégration de la membrane Nanofiltration au procédés de dessalement osmose inverse peut offrir plusieurs avantages, tels qu'une faible pression de fonctionnement, un flux de perméat élevé, une rétention élevée de sels anioniques multivalents et de matières organiques, un investissement relativement faible et des coûts de fonctionnement et de maintenance faibles **(Altaee et Sharif 2011 ; Bertels et al. 2011).**

A cet effet, l'objectif de ce modeste travail est de développer un modèle numérique beaucoup plus développé consiste à appliquer l'apprentissage supervisé et les algorithmes de rétro propagation (back propagation BP) des réseaux de neurones artificiel (RNA) sur l'environnement du logiciel MATLAB, afin d'obtenir un modèle valide du système à commander les performances du système de dessalement hybride NF/OI au cours du temps. Les réseaux de neurones artificiels (RNA) ont été utilisés en raison de leurs flexibilités pour se conformer à tout type des données expérimentales et de leurs succès face à divers problèmes.

Afin de valoriser ces concepts, la structure de cette thèse a été effectuée comme suit :

- **Chapitre 1** : est consacré à la description de dessalement de l'eau de mer, leur technologie de traitement existant,
- **Chapitre 2** : Présente les techniques de modélisation (réseaux de neurones)
- **Chapitre 3** : Comporte la partie expérimentale avec l'interprétation du modèle neuronal élaboré.

Le Manuel est généralement clôturé par une conclusion générale qui résume notre étude .

Chapitre I

Les eaux de mer et notion de potabilité

I.1. Généralité sur les eaux de mer

I.1.1. Définition

Le terme d'eau de mer regroupe l'eau salée des mers et des océans à la surface de la terre. Elles occupent un volume estimé à 1,34 milliards de km³, ce qui représente 97 % de l'eau de la terre. Selon le taux de sel existant dans l'eau de mer ses caractéristiques se modifie on distingue l'eau marine et l'eau saumâtre (**Wright et Colling, 1995**).

L'eau marine se caractérise par leur teneur en sel (chlorure de sodium et de magnésium, sulfate et carbonate). Sa salinité moyenne est de 35g/l. L'eau saumâtre est une eau salée non potable. Sa salinité est inférieure à celle de l'eau de mer et est de 10g/l, ces eaux sont parfois les eaux de surface et le plus souvent les eaux sous terrain l'air composition dépende de sol traversé et de l'air vitesse de circulation (**Mandri et al. 2011**).

I.1.2. Principales compositions de l'eau de mer

I.1.2.1. Constituants inorganiques

L'eau de mer est constituée principalement par des matières inorganiques qui sont divisé en trois groupes distinctes : les éléments majeurs, traces métalliques et nutritifs. Le **Tableau I.1**. Indique la disponibilité des éléments existants dans chaque classe.

- **Eléments majeurs** : En pratique on retient comme constituant principaux ceux qui sont présents en concentration supérieur à **1 (mg. Kg⁻¹)**. Comme les ions de sodium **Na⁺** avec **10770 mg. Kg⁻¹**, Chlore **Cl⁻** avec **19354 mg. Kg⁻¹**, et Sulfate **SO₄²⁻** avec **2712 mg. Kg⁻¹**.
- **Eléments traces métalliques** : Ce sont eux qui ont environs une concentration inferieur a **10⁻³ (mg. Kg⁻¹)**. Par exemples les ions de Titane **Ti** avec **10⁻³ mg. Kg⁻¹**, Cadmium **Cd** Avec **10⁻⁴ mg. Kg⁻¹**, Plombs **Pb** avec **2.10⁻⁵ mg. Kg⁻¹** et le Mercure **Hg** avec une concentration de **10⁻⁵ mg. Kg⁻¹**.
- **Eléments nutritifs**

Le terme d'« éléments nutritifs » comprend donc principalement le nitrate (NO₃⁻) et l'ammoniac (NH₄⁺), le phosphore sous forme phosphate (PO₄³⁻) et le silicium tel que la silice (SiO₂). Les nutriments sont utilisés par les phytoplanctons, cellules végétales de taille d'un à

quelques centaines de microns qui dérivent à la surface des océans et photo-synthétisent des hydrates de carbone, de l'oxyde de carbone et de l'eau.

- **L'azote, le nitrate et l'ammoniac**

Il est nécessaire de distinguer l'azote sous forme de gaz (N_2) et l'azote sous forme d'ions nitrate (NO_3^-), le nutriment. L'azote gazeux est rarement utilisé dans des procédés biologiques marins. L'eau de mer contient environ 11 mg.kg^{-1} d'azote gazeux (N_2), alors que la concentration totale d'azote moyenne est de $11,5 \text{ mg.kg}^{-1}$. Le nitrate constitue donc une petite fraction de l'azote total. Il est dérivé de la décomposition des matières organiques sur terre et est fourni aux océans par les rivières. La pluie fournit également une petite quantité de nitrate produit par la combinaison d'azote et d'oxygène atmosphériques dans la décharge des éclairs, et partiellement aussi la retombée de la pollution industrielle. L'ammoniac (NH_3) est formé pendant la décomposition bactérienne des matières organiques et il est excrété par le zooplancton. L'ammoniac est présent dans l'eau de mer principalement sous la forme d'ions ammonium, (NH_4^+). Il est ultimement oxydé en nitrate, mais il peut être utilisé par les phytoplanctons comme un nutriment et il est la seule source d'azote pour de nombreuses bactéries vivantes libres. (**Benner et al, 1997**).

- **Le silicium**

Il est utilisé pour créer les squelettes des plantes planctoniques (diatomées) et les animaux (radiolaires). Le silicium sécrété par les organismes est une forme amorphe et il est hydraté, donc sa formule est normalement (SiO_2, nH_2O), mais nous utilisons par simplification (SiO_2) pour les deux formes du silicium, solide et dissoute. La concentration du silicium dans l'eau de mer est d'environ 2 mg.kg^{-1} (Tableau I.3). La concentration du silicate (SiO_3^{2-} , SiO_4^{4-} , etc.) dépend de la température de l'eau de mer, elle est plus faible en été qu'en hiver. Par contre, aucun effet de la température n'a été observé sur la quantité de nitrate et de phosphate (**Whitehouse et al, 1996**).

- **Le phosphore**

Il est essentiellement présent dans l'eau de mer sous forme d'ions phosphate (PO_4^{3-}). La concentration totale du phosphore dans l'eau de mer est d'environ $0,06 \text{ mg kg}^{-1}$. Le phosphate est utilisé pour former les tissus souples des organismes (**Whitehouse et al, 1996**).

Tableau I.1 : Concentration usuelles des principaux constituants inorganiques de l'eau de mer (Copin-Montégut, 1996)

Eléments majeurs		Elements traces métalliques		Elements nutritifs		
C en (mg. Kg ⁻¹)		C en (10 ⁻³ mg. Kg ⁻¹)		C en (mg. Kg ⁻¹)		Espèces dissoutes possible
Na⁺	10770	Ti	1	N	11,5	N₂, NO₃⁺, NH₄⁺
Mg²⁺	1290	Zn	0,5			
Ca²⁺	412,1	Ni	0,48			
K⁺	399	Al	0,4	Si	2	Si(OH)₄
Sr²⁺	7,9	Cr	0,3			
B_{total}	4,5	Cd	0,1			
Cl⁻	19354	Cu	0,1			
SO₄²⁻	2712	Fe	0,055	P	0,06	HPO₄²⁻, PO₄³⁻, H₂PO₄⁻
HCO₃⁻ – CO₃²⁻	118-146	Mn	0,03			
Br⁻	67,3	Pb	0,002			
F⁻	1,3	Hg	0,001			

I.1.2.2. Matières organiques

L'océan est le réservoir principal du carbone organique sur terre. La plupart du carbone organique dans l'océan est sous la forme de matière organique dissoute et principalement de molécules à faible poids moléculaire. Seulement 1 % du carbone organique est de la matière organique particulaire (Benner *et al*, 1997). Environ 75 % du carbone organique dissous est de la matière organique dissoute de faible poids moléculaire.

I.1.2.3. Les technologies de dessalement

Le choix de la technologie utilisée pour le dessalement de l'eau dépend d'un certain nombre de facteurs spécifiques au site, notamment la qualité de la source d'eau, l'utilisation de l'eau produite, la taille de l'installation, les coûts d'investissement, les coûts énergétiques (Al-Subaie *et al*.2007).

Le dessalement de l'eau peut être réalisé par différentes techniques pouvant être classées en deux catégories selon le principe appliqué :

- Les procédés thermiques (par vaporisations) basés sur des changements de phase ;
- Procédés membranaires basés sur le transport de l'eau à travers des membranes semi perméable.

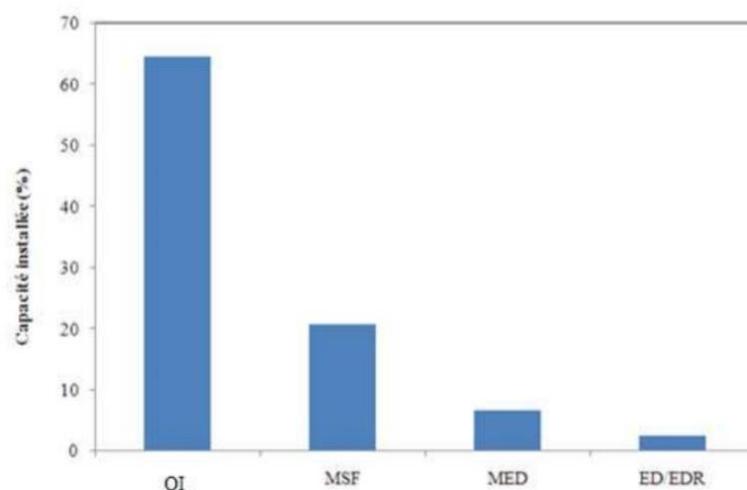


Figure I.1. Capacité totale installations de dessalement le monde (Shemer *et al*.2017)

Il est clairement apparu que le procédé membranaire est le leader du marché. En effet le dessalement par l'osmose inverse (OI), représente 62% de la capacité totale suivi par le processus thermique : Multi stages flash (MSF) et MD avec 24% de la capacité totale. Les 16% restants sont divisé entre les autres procédés, comme l'électrodialyse (ED) avec 5% et compression de vapeur (VC) avec 5%, et d'autres systèmes à conception récente avec 4% (**Al-Karaghoul** *et al.*2009).

Les principales sources d'eau d'alimentation pour le dessalement sont l'eau de mer (58%), eau souterraine saumâtre (23%), et d'autres sources telles que rivières et petits lacs de sel. Le procédé d'osmose inverse nécessite de l'énergie électrique pour alimenter les pompes à hautes pression, par contre les procédés thermiques nécessitent l'énergie sous forme chaleur (**Shemer et al.**2017).

I.2.1 Procédé thermique

Le procédé de distillation consiste à chauffer de l'eau de mer pour évaporer une partie. La vapeur d'eau produite ne contient pas de sels ; il suffit alors de la condenser pour obtenir de l'eau douce (**Babu et al.**2018). Il existe trois grands types de procédés de distillation :

- à effet multiple (MED);
- à multi flash (MSF);
- à compression de vapeur (VC).

L'inconvénient majeur des procédés de distillation est leur consommation énergétique importante liée à la chaleur latente de vaporisation de l'eau.

I.2.1.1 Le procédé de distillation par détente successive (Multi Stage Flash MSF)

Ce procédé dit Flash consiste à maintenir l'eau sous pression pendant toute la durée du chauffage ; lorsqu'elle atteint une température de l'ordre de 120°C, elle est introduite dans une enceinte (ou étage) où règne une pression réduite. Il en résulte une vaporisation instantanée par détente appelée « Flash ». Une fraction de l'eau s'évapore puis va se condenser sur les tubes condenseurs placés en haut de l'enceinte, et l'eau liquide est recueillie en dessous des tubes. C'est l'eau de mer chaude qui se refroidit pour fournir la chaleur de vaporisation, l'ébullition s'arrête quand l'eau de mer a atteint la température d'ébullition correspondant à la pression régnant dans l'étage considéré. Le phénomène de flash est reproduit ensuite dans un deuxième étage où règne

une pression encore plus faible. La vaporisation de l'eau est ainsi réalisée par détentes successives dans une série d'étages où règnent des pressions de plus en plus réduites. On peut trouver jusqu'à 40 étages successifs dans une unité MSF industrielle (Ullah et Rasul 2019).

Pour chauffer l'eau de mer jusqu'à 120°C, l'eau de mer circule d'abord dans les tubes des condenseurs des différents étages en commençant d'abord par le dernier étage où la température est la plus faible, elle est alors préchauffée en récupérant la chaleur de condensation de la vapeur d'eau. Elle est finalement portée à 120 °C grâce à de la vapeur à une température supérieure à 120°C produite par une chaudière ou provenant d'une centrale de production d'électricité (El-Ghonemy 2017).

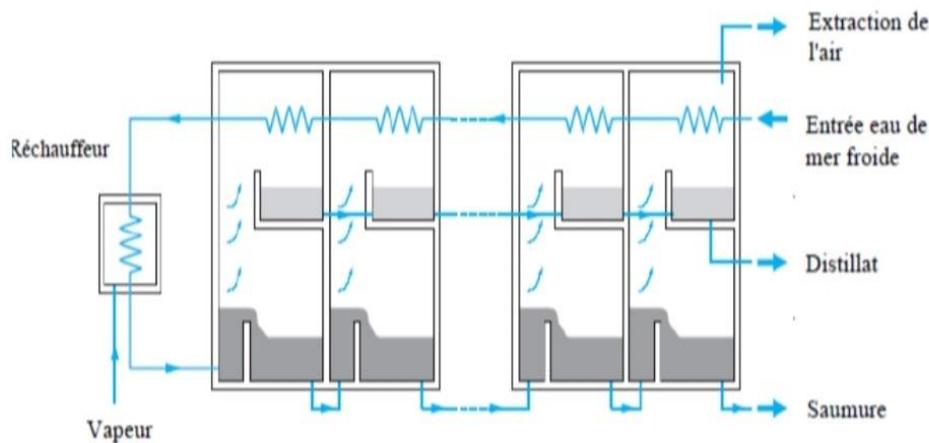


Figure I.2. Schéma de principe de la distillation multi stage flash distillation (El- Ghonemy 2017)

I.2.1.2 Le procédé de distillation à multiples effets (Multi-Effects Distillation MED)

Ce procédé est basé sur le principe de l'évaporation, sous pression réduite, d'une partie de l'eau de mer préchauffée à une température variant entre 70 et 80°C. L'évaporation de l'eau a lieu sur une surface d'échange, contrairement au procédé précédent, où elle est assurée par détente au sein des étages successifs (Madani *et al.*1994). La chaleur transférée au travers de cette surface est apportée soit par une vapeur produite par une chaudière, soit par une eau chaude provenant d'un récupérateur de chaleur. La vapeur ainsi produite dans le 1er effet est condensée pour produire de l'eau douce dans le 2ème effet où règne une pression inférieure, ainsi la chaleur de condensation qu'elle cède permet d'évaporer une partie de l'eau de mer contenue dans le 2ème effet et ainsi de suite (voir figure I.3) (Al-Karaghoul *et al.*2009).

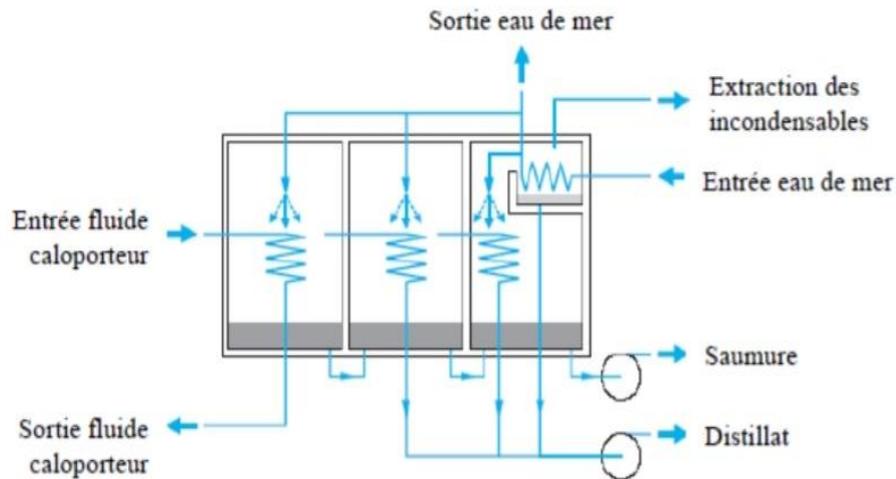


Figure I.3.Schéma de principe de la distillation Multiple Effect (MED) (Al-Karaghoul *et al.* 2009).

I.2.1.3. Multi-effets avec compression de vapeur

Compression de vapeur (VC) est un processus dans lequel la chaleur nécessaire à l'évaporation de l'eau provient de la compression (au lieu du chauffage direct). L'eau d'alimentation entre par un échangeur de chaleur et de la vapeur est générée dans l'évaporateur. Ensuite, la vapeur est comprimée, soit par des moyens mécaniques (MVC) (Al-Karaghoul *et al.* 2013) soit thermiques (TVC). La compression augmente la température de la vapeur afin qu'elle serve de source de chaleur à l'évaporateur. Le flux de saumure est également divisé, une partie étant mélangée à l'eau d'alimentation entrante.

La plage typique de capacité de production de VC est comprise entre 100 et 3000 m³/jour pour le MVC et entre 10 000 et 30 000 m³/jour pour le TVC. Le VC est souvent utilisé en combinaison avec d'autres processus tels que MED pour améliorer l'efficacité globale (Blagin *et al.* 2018).

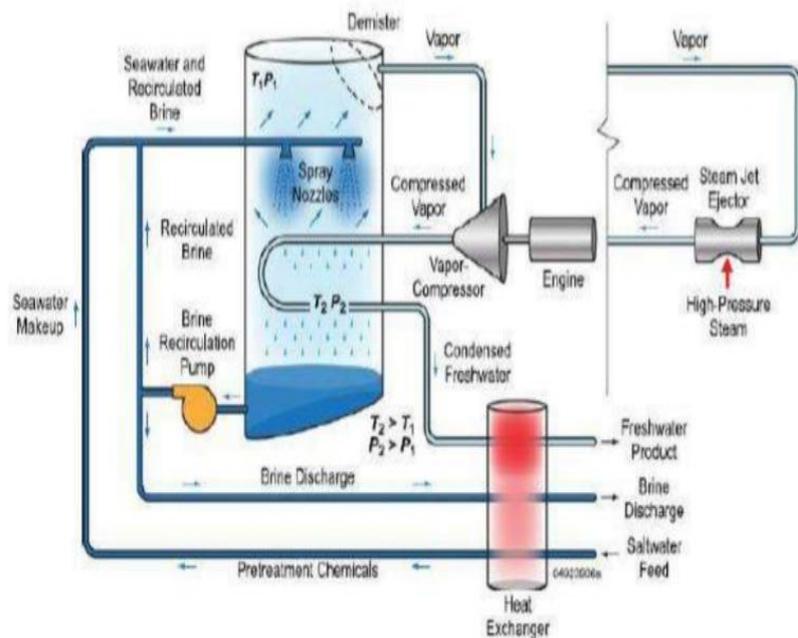


Figure I.4. Compression mécanique de vapeur à un seul effet (Al- Karaghoulouli *et al.* 2013).

I.2.2. Filtration membranaire

La filtration membranaire est une technique de séparation liquide/liquide, liquide/solide, liquide/gaz ou gaz/gaz qui fait intervenir une membrane semi-perméable et sélective sous l'effet d'une force motrice. Cette force motrice peut être soit un gradient de pression (cas de l'osmose inverse (OI), de la Nanofiltration (NF), de l'ultrafiltration (UF) et de la microfiltration (MF), qu'il repose sur une différence de pression entre le milieu et la membrane, appelée pression transmembranaire (PTM) (Chollom *et al.* 2015). Un gradient de concentration (cas de la dialyse) ou un gradient de potentiel électrique (cas de l'électrodialyse).

I.2.2.1. Les techniques membranaires à gradient de pression

Les constituants qui sont plus petits que les pores de la membrane sont capables de passer à travers la membrane sous l'effet d'une pression appliquée tandis que les substances et les molécules de taille plus importante sont retenues par la membrane.

- **Microfiltration (MF)**

La séparation par microfiltration concerne en générale les particules en suspension, les micro-organismes, macromolécules (polymères) pour laquelle la taille des pores de membranes se

situant entre 0.1 et 10 μm , les pressions appliquées sont très faible inférieur de 2 bars pour éviter le colmatage (Zeman et Zydney 2017).

- **L'ultrafiltration (UF)**

UF est une technique utilise des membranes macroporeuses, dont les diamètres des pores sont entre 1 et 100 nm, et les pressions sont supérieures à celle rencontrées en microfiltration entre 1-10 bars. Cette technique permettre la séparation des macromolécules et d'espèces colloïdales (polymères, protéines) (Wu *et al.*2017).

- **Nanofiltration (NF)**

NF est une technique de séparation par membranes dont le champ d'application se situe entre ceux de l'osmose inverse et de l'ultrafiltration. De plus, cette technique retient les sels bivalents et les molécules de l'ordre de 0.001 μm et nécessite une pression de travail de 10 à 25 bars. Comparée à l'osmose inverse les membranes de nanofiltration sont moins dense ce qui permet d'obtenir des flux de perméat supérieurs pour des pressions inférieures, cela implique que ce procédé est moins couteux et moins consommateur d'énergie.

- **I.2.2.1.4. L'osmose inverse**

Un procédé d'osmose inverse est le cœur du procédé de dessalement. L'osmose inverse consiste donc à appliquer à l'eau salée une forte pression pour la forcer à traverser une série de membranes semi-perméables. Les sels sont retenus par ces membranes qui sont généralement enroulées en spirale à l'intérieur d'un tube afin d'augmenter la surface de filtration, tandis que seules les molécules d'eau les traversent. Une unité de membrane OI (figure I.5) se compose de quatre éléments de base (Akther *et al.* 2015) :

- Prétraitement ;
- Pompes à haute pression ;
- Bloc membrane ;
- Post-traitement.

Le Prétraitement a pour objectif la réduction du colmatage, l'augmentation de la durée de vie des membranes, l'amélioration de la qualité de l'eau produite et la maintenance des

performances de l'osmose inverse. Les procédés de prétraitement peuvent être divisés en deux catégories : les prétraitements physiques et les prétraitements chimiques. Les premiers incluent les préfiltres mécaniques, les filtres à cartouche, la filtration à sable et la filtration membranaire. Le prétraitement chimique consiste en l'addition d'inhibiteurs d'entartrage, de coagulants, de désinfectants et de poly-électrolytes (Berland et Juery 2002).

La pompe haute pression permet ensuite d'injecter l'eau de mer sous une pression de l'ordre de 50 à 80 bars qui dépend de la salinité et de la température de l'eau dans le module d'osmose inverse (Khawaji 2008).

Les deux modules commerciaux les plus fréquents dans le marché sont les modules spiraux et à fibres creuse. Au sein des modules spiraux (figure I.5), une membrane plane est enroulée sur elle-même autour d'un tube poreux (le collecteur du perméat) qui recueille le filtrat. On obtient ainsi un cylindre multicouche où le perméat s'écoule selon un chemin spiralé vers le tube poreux tandis que l'alimentation circule axialement dans les canaux (Arzate 2008).

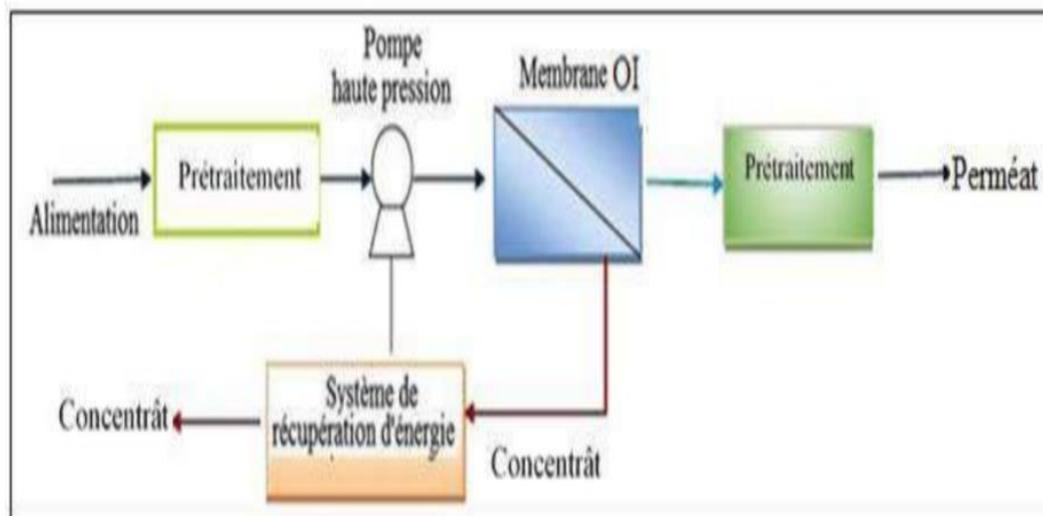


Figure. I.5. Schéma de principe d'une unité d'osmose inverse.

I.2.2.2. Technique membranaire à gradient de potentiel électrique

L'électrodialyse est le procédé le plus largement appliqué parmi les techniques électromembranaires (Singlande 2006).

C'est une technique utilisant un empilement de membranes échangeuses d'ions disposées en alternance orthogonalement à un champ électrique (**Bribieska 2005**).

Dans une unité d'électrodialyse, les membranes cationiques (perméables aux cations) MEC et les membranes anioniques (perméables aux anions) MEA sont disposées parallèlement et de manière alternée (figure I.6). Sous l'action du champ électrique appliqué à l'aide d'une anode et d'une cathode, les MEC bloquent les anions et laissent passer les cations, tandis que les MEA bloquent les cations et laissent passer les anions. Il se crée alors, des compartiments de concentration (concentrat) et d'autres de dilution (diluats). Les solutions sont renouvelées dans les compartiments par une circulation parallèle au plan des membranes. L'injection du courant dans le système est assurée par deux électrodes parallèles au plan des membranes et placées aux extrémités de l'électro-dialyseur (**Hamani 2013**).

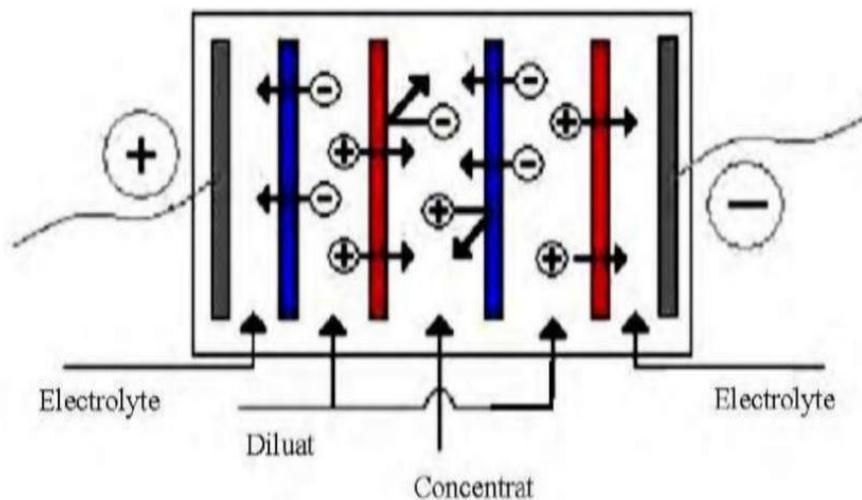


Figure I.6. Principe de l'électrodialyse conventionnelle (**Hamani 2013**).

I.3. Dessalement par procédé hybride Nanofiltration/Osmose inverse

D'autres types de membranes comme la Nanofiltration NF ont été suggérés comme alternative au Osmose inverse OI pour le dessalement de l'eau de mer où le principal avantage de la NF est de réduire la consommation d'énergie en raison de la plus grande perméabilité du NF comparée à la OI (**Altaee et Sharif 2011 ;Bartels et al. 2011**). Il présente un taux de rejet modéré entre OI et ultrafiltration (UF), avec des taux de rejet plus élevés pour les ions divalents supérieurs

à 98% selon la structure de la membrane (**Alnouri et Linke 2013**). Cependant, la mise en œuvre de procédé hybride Nanofiltration/Osmose Inverse par rapport au procédé d'osmose inverse seule a conduit à des résultats particulièrement intéressants : un taux de rétention en matières organiques élevé (70 %) et un colmatage très réduit.

I.4. Procédé de prétraitement de l'osmose inverse

Le prétraitement a pour objectif la réduction du colmatage, l'augmentation de la durée de vie des membranes, l'amélioration de la qualité de l'eau produite et la maintenance de l'unité de l'osmose inverse. Les procédés de prétraitement peuvent être divisés en deux catégories : les prétraitements physiques et les prétraitements chimiques. Les prétraitements physiques incluent les préfiltres mécaniques, les filtres à cartouche, la filtration à sable et la filtration membranaire. Le prétraitement chimique consiste en l'addition d'inhibiteurs d'entartrage, de coagulants, de désinfectants et de poly-électrolytes (**Berland et Juery2002**). A l'heure actuelle, la plupart des usines d'osmose inverse utilisent un procédé de prétraitement conventionnel qui généralement consiste en un prétraitement physique et chimique sans procédé membranaire. Avec la baisse constante du prix des éléments membranaires et la dégradation de la qualité des ressources en eau, le prétraitement par procédé membranaire trouve de plus en plus sa place dans les étapes de prétraitement avant osmose inverse.

I.5. Conclusion

Le dessalement est un enjeu particulièrement important pour l'avenir des régions sujettes aux pénuries d'eau. C'est une méthode d'avenir pour pallier aux problèmes d'eau douce. Beaucoup de pays des régions touchées par la pénurie d'eau ont recouru au dessalement de l'eau de mer pour répondre aux besoins des populations, de l'industrie, de l'agriculture et du tourisme.

L'Algérie a opté, dans la grande majorité des stations, la technique d'Osmose Inverse avec des taux de conversion environ 50%. Le procédé de dessalement de l'eau de mer par osmose inverse a connu un grand développement et présente beaucoup d'avantages par rapport au procédé de distillation. Le recours au dessalement est également renforcé par la diminution des coûts de production par m³, en raison, principalement, de l'amélioration de la technologie et de la concurrence.

Les performances membranaires sont limitées par le facteur de colmatage et phénomène de polarisation. En effet, au cours des dernières décennies, plusieurs travaux montrent que la technologie Nanofiltration est alternative de l'osmose inverse grâce à sa basse pression d'opération, la haute rétention des ions monovalents et matière organique. L'intégration de NF avec OI engendre les avantages des deux technologies, le couplage entre les procédés donnera une efficacité sur l'aspect économique, augmente la production et diminue la consommation énergétique.

Chapitre II

**Technique de
modélisation (réseau de
neurone)**

II.1. Introduction

Les réseaux de neurone fabriqués de structures cellulaires artificielles constituant une des approches permettant d'aborder sous des angles nouveaux les problèmes de perception, de mémoire, d'apprentissage et de raisonnement. Ils s'avèrent aussi des alternatives très prometteuse pour contourner certaines des limitations des ordinateurs classiques grâce à leur traitement parallèle de l'information et leur mécanismes inspirés des cellules nerveuses neurones, ils infèrent des propriétés émergentes permettant de solutionner des problèmes jadis qualifiés de Complexe. **(M parizian) (Intelligence artificielle,2019)**

Les réseaux de neurones artificielles appartiennent à la catégorie des techniques statistiques de classification automatique, leur architecture, ainsi que leur fonctionnement qui sont inspirés par la massive interconnectivité du cerveau humain et sa capacité à résoudre des problèmes non linéaires sans faire d'hypothèse sur les données faisant un outil performant dans l'abstraction et la visualisation des données. **(Intelligence artificielle,2019)**

L'objectif de notre étude est de modéliser les paramètres de déminéralisation de l'eau de mer ; on va commencer par présenter à l'aperçu général sur la modélisation et les réseaux de neurones CTA leur architecture, leur fonctionnement et leur utilisation et leur type Etc

Ensuite on s'intéresse à la méthode de génération de la base de données dans la partie pratique.

II.2. Généralités sur la modélisation

II.2.1. Le modele mathématique :

En génie de procédés le modèle mathématique est un excellent moyen de capitaliser de la connaissance et peut être considéré comme un vecteur essentiel du transfert de connaissance acquises en recherche vers les unités opérationnelles et décisionnelle il permet de pouvoir comprendre les phénomènes physique, chimiques et biologiques mis en pour mieux concevoir, optimiser, faire fonctionner contrôler et faire évoluer les procédés.

Les modèles peuvent être utiles dans toutes les phases d'interrogatoire : de l'étape de recherche et développement à la conduite du procédé et pour les études économiques dans la

mesure du possible, l'activité de modélisation et le développement du procédé doivent donc se faire de manière simultanée

II.2.2. Définitions

- **Systeme :**

Ensemble de processus, il comporte des entrées et des sorties. Ses entrées sont les paramètres qui agissent sur son comportement. Elles peuvent être contrôlées ou non. Ses sorties sont les paramètres résultat des valeurs données aux entrées.

- **Procédé :**

un procédé est un moyen utilisé en vue de produire quelque chose.

- **Processus :**

c'est l'ensemble d'opérations unitaires permettant la transformation de matières premières en produit .

- **Modélisation :**

définir la modélisation en génie de procédés c'est une tâche délicate tant elle recouvre d'action et d'objectifs divers dans tous les cas il s'agit de construire une représentation la plus proche possible du fonctionnement ou de réagir à un comportement .

a- modèle en génie des procédés le terme "modèle" se réfère à un ensemble d'équations mathématiques construit sur la base de données expérimentales acquises sur le système réel et permettant de représenter les relations entre les sorties et les entrées du système .

- **Simulation :**

la simulation consiste alors à conduire des expériences sur le modèle pour en déduire les performances du système , prédire son comportement , tester sa conformité aux normes etc il s'agit souvent d'utiliser des logiciels pour la programmation des modèles analytiques ou descriptifs et leur manipulations afin de réaliser et visualiser des expérimentations .

II.3. Réseaux de Neurone

II.3.1. Aperçu général

Au cours des deux dernières décennies, le développement des réseaux de neurones est devenu fulgurant. Cet intérêt a démarré avec l'application réussie de cette technique puissante pour

des problématiques très différentes, et dans des domaines aussi divers que la finance, la médecine, la production industrielle, la géologie ou encore la physique et la mécanique des fluides.

Le succès croissant des réseaux de neurones sur la plupart des autres techniques statistiques peut s'attribuer à leur puissance, leur polyvalence et à leur simplicité d'utilisation. Les réseaux de neurones sont des techniques extrêmement sophistiquées de modélisation et de prévision, en mesure de modéliser des relations entre des données ou des fonctions particulièrement complexes. **(Intelligence artificielle,2019;Patterson1996).**

La possibilité d'apprendre sur la base d'exemples constitue l'une des nombreuses Fonctionnalités des réseaux de neurones qui permettent à l'utilisateur de modéliser ses données et établir des règles précises qui vont guider les relations sous-jacentes entre différents attributs de données. L'utilisateur des réseaux de neurones collecte des données représentatives puis il fait appel aux algorithmes d'apprentissage, qui vont apprendre automatiquement la structure des données. Si l'utilisateur n'a besoin d'aucune connaissance heuristique particulière sur la manière de sélectionner et préparer ses données, sur le bon réseau de neurones à choisir, ni sur la manière d'interpréter les résultats, le niveau de connaissance dont l'utilisateur a besoin pour réussir à appliquer des réseaux de neurones est nettement inférieur à celui qu'il doit posséder pour la plupart des techniques et outils traditionnels, en particulier lorsque les algorithmes des réseaux de neurones sont intégrés dans des programmes intelligents et bien conçus qui vont les prendre en main du début à la fin en à peine quelques clics.

II.3.2. Utilisation des Réseaux de Neurones :

Les réseaux de neurones ont une remarquable faculté à donner un sens, extraire des règles et des tendances à partir de données compliquées, bruitées et imprécises. Ils peuvent s'utiliser pour extraire des modèles et détecter des tendances reposant sur des fonctions mathématiques compliquées qui sont trop difficiles, voire impossible, à modéliser à l'aide des techniques analytiques ou paramétriques traditionnelles. L'une des propriétés intéressantes des réseaux de neurones est qu'ils savent prévoir avec précision des données qui ne faisaient pas partie des données d'apprentissage, un processus connu sous le nom de généralisation.

Compte tenu de ces caractéristiques et de leur domaine d'application étendu, les réseaux de neurones sont particulièrement bien adaptés à l'application de problématiques concrètes dans les domaines de la recherche scientifique, commerciale et industrielle.

II.3.3. L'inspiration biologique :

Les réseaux de neurones sont également assez séduisants dans la mesure où la plupart de leurs principes reposent sur des modèles intrinsèques de systèmes de neurones biologiques du traitement de l'information, qui ont conduit au développement de systèmes informatiques plus intelligents, applicables dans des problématiques statistiques et d'analyse des données. Les réseaux de neurones sont apparus lors des recherches sur l'intelligence artificielle, avec pour but de répliquer la tolérance à la faute et la "faculté d'apprendre" que l'on rencontre dans les systèmes biologiques de neurones, en modélisant la structure intrinsèque du cerveau (**Patterson, 1996**).

Le cerveau est en réalité constitué d'un très grand nombre de neurones (de l'ordre de cent milliards), étroitement connectés entre eux par plusieurs milliers d'interconnexions pour chaque neurone. Chaque neurone est une cellule spécialisée, capable de créer, envoyer et recevoir des signaux électrochimiques. Comme toutes les cellules biologiques, les neurones possèdent un corps cellulaire, des prolongements apportant des informations au neurone (les dendrites), et un prolongement qui communique les informations recueillies par le neurone (les axones). L'axone d'une cellule est connecté aux dendrites d'une autre par l'intermédiaire d'une synapse. Lorsqu'un neurone est activé, il envoie un signal électrochimique au travers de l'axone. Cette impulsion traverse les synapses vers des milliers d'autres neurones, qui peuvent à leur tour, envoyer et donc propager le signal à l'ensemble du système neuronal (c'est-à-dire, le cerveau biologique). Un neurone ne va émettre une impulsion que si le signal transmis au corps cellulaire par les dendrites dépasse un certain seuil appelé seuil de déclenchement (Figure II.1).

Si un neurone n'est pas en mesure d'accomplir une tâche à lui tout seul, les résultats peuvent devenir spectaculaires dès lors qu'un grand nombre de neurones unissent leurs efforts. Ils peuvent ainsi créer ou accomplir diverses tâches cognitives extrêmement complexes comme l'apprentissage ou même le savoir. Par conséquent, grâce à un très grand nombre d'unités rudimentaires de traitement, le cerveau réussit à réaliser des tâches extrêmement complexes. Bien évidemment, il est intéressant de noter que les réseaux de neurones artificiels sont en mesure d'obtenir des résultats remarquables

en utilisant un modèle qui n'est finalement guère plus complexe que celui-ci (Mc culoch et pitts 1943).

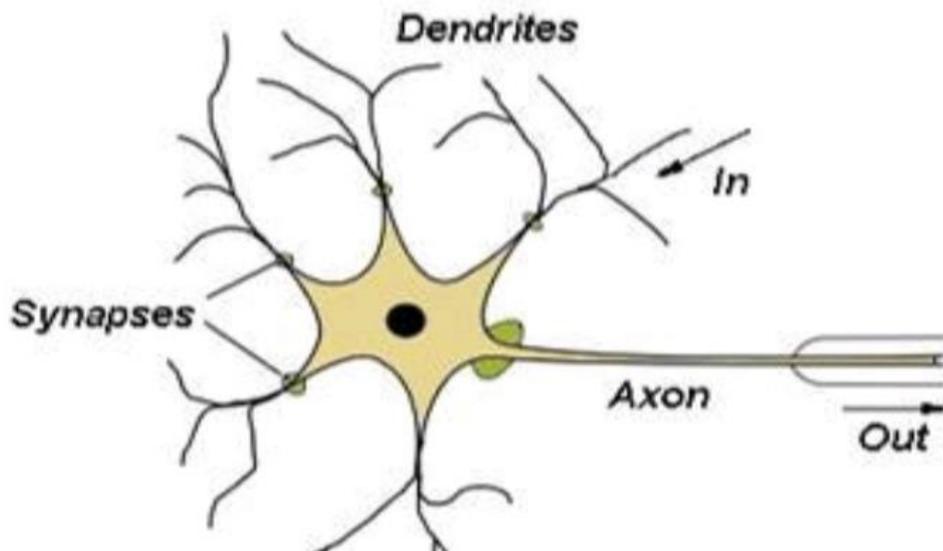


Figure II.1 Neurone biologique schématisé

II.3.4. Les Fondements du Modèle Mathématique

Considérons ici la forme la plus simple des réseaux de neurones artificiels constitué d'un seul neurone avec un certain nombre d'entrées et une seule sortie (dans un souci de simplification). Bien entendu, les réseaux de neurones artificiels dans les applications concrètes sont généralement constitués de beaucoup plus de neurones, mais ce modèle va aider à comprendre la logique de cette technologie.

Le neurone reçoit des signaux en provenance de différentes sources. Ces sources proviennent généralement des données et sont appelées les variables d'entrée x , ou plus simplement les entrées. Les entrées arrivent au neurone par l'intermédiaire d'une connexion avec une certaine force, connue sous le nom de poids. L'importance d'un poids est représentée par une valeur. Plus la valeur d'un poids w est importante, plus l'intensité du signal entrant est forte, et donc, plus l'entrée correspondante est influente.

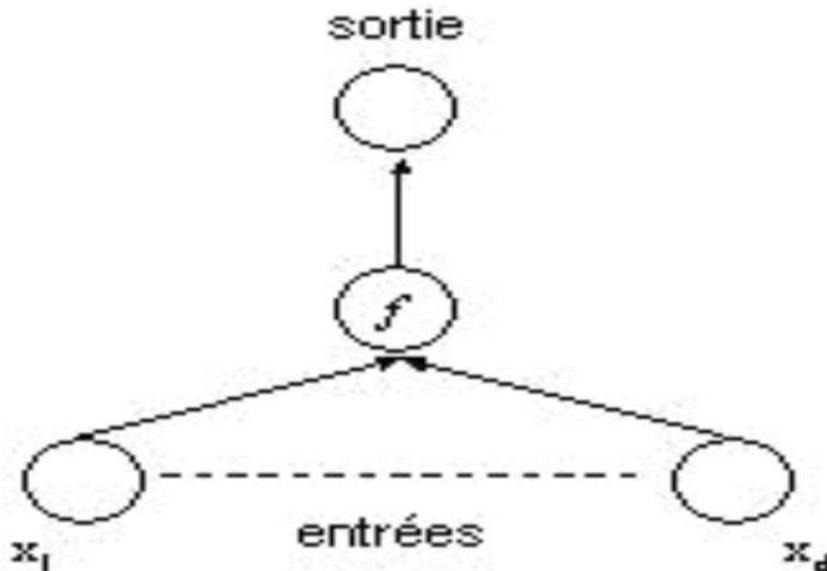


Figure II.2. Modèle à un seul neurone

Lors de la réception des signaux, une somme pondérée des entrées est calculée pour constituer la fonction d'activation f (ou plus simplement, l'activation) du neurone. L'activation du neurone est une fonction mathématique qui convertit la somme pondérée des signaux afin de produire la sortie du neurone. Par conséquent :

$$\text{Sortie} = f (W_1 X_1 + \dots W_d X_d)$$

La sortie d'un neurone est en réalité la prévision du modèle à un seul neurone pour une variable du jeu de données, et qui s'appelle la cible t . Nous considérons qu'il existe une relation entre les entrées x et les cibles t , et c'est au réseau de neurones que revient la tâche de modéliser cette relation en reliant les entrées aux cibles par une fonction mathématique adaptée qui peut être apprise sur la base d'exemples issus du fichier de données.

II.3.5. Réseaux de Neurones Non-Bouclés (Réseaux Feed-forward):

Le modèle évoqué ci-dessus est le modèle de réseaux de neurones le plus simple que nous puissions construire. Ce modèle nous a permis d'expliquer les principes et fonctionnalités élémentaires des réseaux de neurones et de décrire un neurone individuel.

Toutefois, comme indiqué par ailleurs, un seul neurone n'est pas en mesure d'effectuer une tâche significative à lui seul. En revanche, de nombreux neurones interconnectés ont la possibilité d'atteindre un but spécifique. Examinons à présent d'autres architectures de réseaux de neurones qui sont utilisées dans des applications concrètes.

Pour pouvoir être utilisé, un réseau doit posséder des entrées (qui portent les valeurs des variables étudiées dans le monde externe) et les sorties (qui constituent les prévisions, ou signaux de contrôle). Les entrées et les sorties correspondent aux nerfs moteurs et sensoriels au même titre que ceux qui relient les yeux aux mains. Toutefois, il peut exister des neurones cachés qui vont jouer un rôle interne dans le réseau. Il est nécessaire que les neurones d'entrée, les neurones cachés et les neurones de sortie soient connectés (**McCulloch 1943**).

Les réseaux de neurones les plus simples possèdent une structure feed-forward (ou non-bouclée) c'est-à-dire une structure dans laquelle les neurones ne sont connectés que dans un sens : les signaux provenant des entrées traversent les unités cachées pour éventuellement atteindre les unités de sortie. Une structure de ce type possède un comportement stable et une tolérance à la faute. Les réseaux de neurones non bouclés (feed-forward) sont de loin les plus efficaces pour aborder les problématiques concrètes et sont par conséquent les plus utilisés.

Voir Bishop, 1995 pour plus d'informations sur les différents types et architectures de réseaux de neurones.

Un réseau feed-forward type possède des neurones organisés dans des couches distinctes. D'une manière générale, la couche d'entrée sert simplement à introduire les valeurs des variables d'entrée. Les neurones de la couche cachée et de la couche de sortie sont connectés chacun à toutes les unités de la couche précédente.

À nouveau, il est possible de définir des réseaux partiellement connectés à certaines unités spécifiques de la couche précédente. Toutefois, dans la plupart des applications, les réseaux totalement connectés sont préférables. Lors de l'exécution du réseau, les valeurs des variables d'entrée sont envoyées dans les unités d'entrée, puis les unités de la couche cachée et de la couche de sortie sont progressivement exécutées en ordre séquentiel. Chacune de ces unités va calculer une valeur d'activation en utilisant la somme pondérée des sorties des unités de la couche précédente. La valeur d'activation est alors envoyée à la fonction d'activation qui va

produire la sortie du neurone. Lorsque l'ensemble du réseau a été exécuté, les neurones de la couche de sortie deviennent les sorties de l'ensemble du réseau (Hamadach,2014).

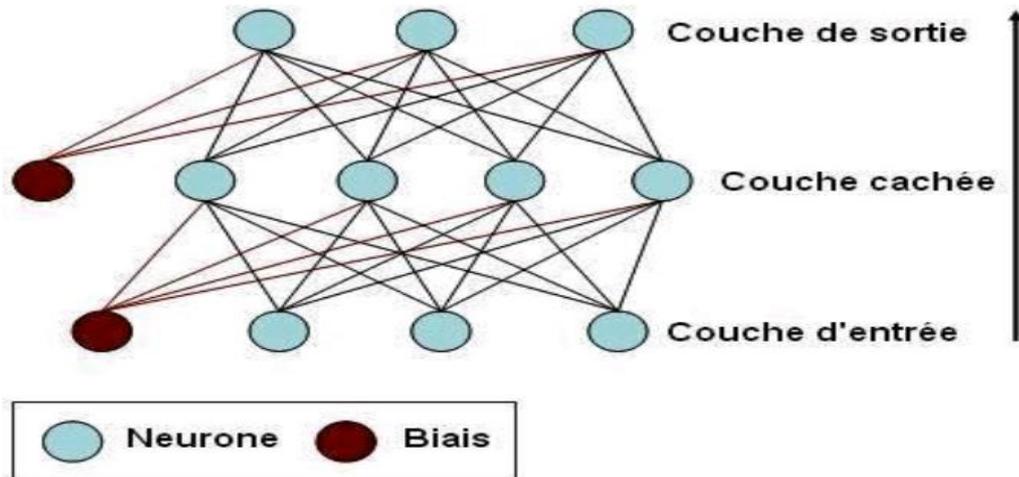


Figure II.3 Schéma d'un réseau de neurones PMC totalement connecté à trois entrées, quatre unités cachées (neurones), et trois sorties.

II.3.6 Types de Réseaux de Neurones

On se contentera dans le présent mémoire aux réseaux de neurones de type Perceptrons Multicouches.

1- Les Réseaux de Neurones Perceptrons Multicouches:

Les Perceptrons multicouches (PMC) constituent sans conteste l'architecture la plus fréquemment utilisée actuellement. Nous devons cette architecture à Rumelhart et McClelland (1986). Chaque neurone va en fait calculer une somme pondérée de ses entrées qu'il va transmettre à une fonction de transfert f afin de produire ses sorties. Pour chaque couche du réseau de neurones dans un réseau PMC, il existe également un terme de biais. Un biais est un neurone dans lequel la fonction d'activation est en permanence égale à 1. Comme pour les autres neurones, un biais se connecte aux neurones de la couche précédente par l'intermédiaire d'un poids. Les neurones et les biais sont organisés dans une structure découches non-bouclées (feed-forward). Le réseau peut donc s'interpréter simplement comme un modèle entrée-sortie, les poids étant les paramètres libres (ajustables) du modèle. Ces réseaux sont en mesure de modéliser des fonctions même très complexes, où le nombre de couches et le nombre d'unités dans chaque couche va déterminer la

complexité de la fonction. (**Ben rabe** **et all 2015**) .

Lors de la conception des Perceptrons Multicouches, il est important de bien spécifier le nombre de couches cachées ainsi que le nombre d'unités dans ces couches. (**Bishop, 1995**) Mais il est également important de bien choisir les fonctions d'activation et les méthodes d'apprentissage.

II.3.7. Fonctions d'Activation :

Comme indiqué précédemment, un perceptron multicouche (PMC) est un réseau de neurones avec une architecture feed-forward et des connexions unidirectionnelles complètes entre les différentes couches. Toutefois, ce n'est pas suffisant pour définir les propriétés d'un réseau. Outre les architectures de réseaux, les neurones d'un réseau possèdent des fonctions d'activation qui vont transformer les signaux émis par les neurones de la couche précédente à l'aide d'une fonction mathématique. Cette fonction est la fonction d'activation elle-même, et elle peut profondément influencer sur la performance du réseau. Il est donc important de bien choisir de type de fonction d'activation des neurones dans un réseau de neurones (**Rivales et all 1995**).

Les neurones d'entrée ne possèdent généralement aucune fonction d'activation. En d'autres termes, ils utilisent la fonction identité, ce qui signifie que les signaux d'entrée ne sont nullement transformés. Ils sont au contraire combinés avec une somme pondérée (par les poids de la couche entrée-cachée) et sont ensuite transmis aux neurones de la couche suivante (généralement appelée la couche cachée). Pour un PMC à deux couches (PMC2), il est conseillé d'utiliser la fonction tangente hyperbolique même si d'autres types sont également possibles comme les fonctions : logistique, sigmoïde et autres... Les fonctions d'activation des neurones de sortie sont, dans la plupart des cas, la fonction identité mais ce choix peut varier d'une tâche à l'autre. Par exemple, pour des problématiques de régression, nous utilisons la fonction identité (avec une fonction tanh pour les neurones cachés).

Un neurone d'un perceptron multicouche se caractérise par trois concepts: son état, ses connexions avec d'autres neurones, et sa fonction d'activation.

Avec:

X_i : l'entrée i ;

A_j : Etat du neurone j de la couche cachée (égale à la somme pondérée de toutes les entrée X_i plus un biais) ;

W_{ij} : Poids de la connexion entre les neurones j et i (entre la couche d'entrée et la couche cachée);

W_{kj} : Poids de la connexion entre les neurones j et k (entre la couche de sortie et la couche cachée).

1) La fonction identité : $f(A) = A$

2) La fonction sigmoïde : $f(A) = \frac{1}{1+e^{-A}}$

3) La fonction Tangente hyperbolique : $f(A) = \frac{e^A - e^{-A}}{e^A + e^{-A}}$

La construction d'un réseau de neurones multicouches consiste à choisir le nombre de neurones et leurs fonctions de transfert, à déterminer les connexions par les neurones et à fixer les poids de ces derniers. L'attrait de cette approche réside dans le fait qu'en ne changeant que les poids des connexions, on peut utiliser une vaste gamme de fonctions différentes, et qu'il existe une méthode générique pour régler les poids des connexions, appelée règle d'apprentissage.

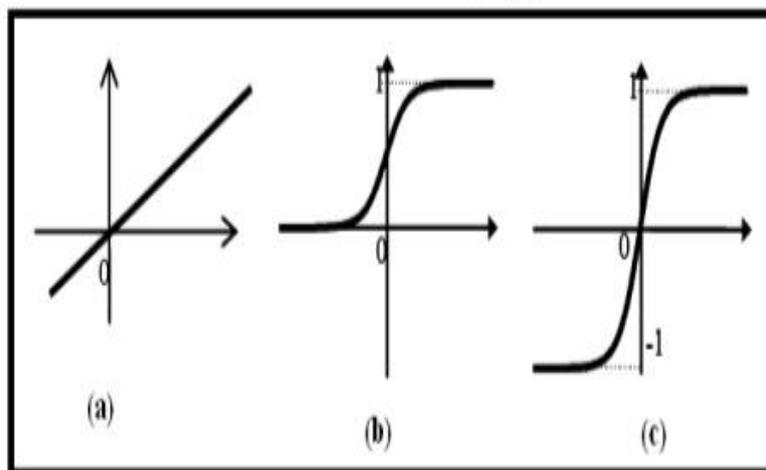


Figure II.4. Différentes fonction d'activation : (a) Linéaire. (b) Sigmoïde et (c) Tangente hyperbolique

II.3.8. Sélection des Variables d'Entrée :

Le nombre d'unités d'entrée et d'unités de sortie est déterminé par le problème. La variable cible est censée dépendre des entrées donc son choix est clair. Ce n'est en revanche pas aussi évident pour le choix des entrées. Il peut précisément exister une certaine incertitude quant aux entrées à utiliser. Il faut savoir que le choix d'un nombre suffisant de bons prédicteurs est d'une importance cruciale pour la modélisation prédictive (c'est-à-dire la mise en relation d'une variable

cible et d'un ensemble d'entrées) et en fait, pour toutes les formes d'analyses statistiques. Si nous intégrons des entrées qui n'ont pas véritablement de lien avec la variable cible, nous pouvons par exemple détériorer sans nous en rendre compte la performance du réseau de neurones. À l'inverse, un fichier de données comportant un nombre insuffisant d'entrées pourra ne jamais être modélisé de façon précise par un réseau de neurones.

II.3.9. Complexité du Réseau de Neurones :

La complexité des réseaux de neurones se mesure par le nombre de neurones dans la couche cachée. Plus un réseau de neurones comporte de neurones, plus le système sera flexible mais également complexe. Des réseaux de neurones flexibles permettent d'approcher des fonctions de n'importe quelle complexité entre les variables d'entrée et les variables cible. Par conséquent, pour modéliser un fichier de données, il est important d'utiliser des réseaux de neurones relativement flexibles, contenant suffisamment de neurones dans la couche cachée. Le choix du nombre optimal de neurones dépend en grande partie du domaine de la problématique, mais d'une manière générale, il est lié au nombre d'entrées.

II.3.10. Apprentissage du Réseau :

- **Apprentissage des Réseaux de Neurones :**

Une fois que nous avons choisi l'architecture du réseau de neurones, c'est-à-dire le type de réseau de neurones, les fonctions d'activation, etc....., nous devons déterminer les autres paramètres ajustables du modèle que sont les poids qui permettent de connecter les entrées aux neurones cachés et les neurones cachés aux neurones de sortie. Le processus d'ajustement de ces paramètres de telle sorte que le réseau soit en mesure d'approcher la relation fonctionnelle sous-jacente entre les entrées x et les cibles t est connu sous le nom d'apprentissage. C'est au cours de ce processus que le réseau de neurones va apprendre à modéliser les données par des exemples. Bien qu'il existe différentes manières de réaliser l'apprentissage des réseaux de neurones, la plupart d'entre elles utilisent des algorithmes numériques qui sont en mesure d'effectuer la tâche au cours d'un nombre fini d'itérations.

Nous avons recours à ces algorithmes itératifs essentiellement en raison de la nature fortement non-linéaire des modèles de réseau de neurones pour lesquels une solution en forme fermée n'est

généralement pas disponible. Un algorithme d'apprentissage itératif va ajuster graduellement les poids du réseau de neurones de telle sorte que pour toute donnée d'entrée x , le réseau de neurones est en mesure de produire une sortie aussi proche que possible de t .

- **Initialisation des Poids :**

Puisque l'apprentissage des réseaux de neurones fait appel à un algorithme itératif au cours duquel les poids sont ajustés, il faut tout d'abord initialiser les poids avec des valeurs de départ raisonnables. Car ce sont non seulement la qualité de la solution mais également le temps nécessaire pour préparer le réseau (apprentissage), qui sont en jeu. Il est important d'initialiser les poids en utilisant de petites valeurs pour les poids de sorte que, au début de l'apprentissage, le réseau fonctionne en mode linéaire, puis qu'il augmente les valeurs de ses poids afin d'ajuster les données avec suffisamment de précision.

- **Apprentissage du Réseau de Neurones - Apprentissage par les Exemples :**

Un réseau de neurones n'est pas en mesure de faire des prévisions s'il n'a pas été entraîné préalablement sur des exemples connus sous le nom de données d'apprentissage. Les données d'apprentissage sont généralement constituées de couples entrée-cible qui sont présentés au réseau les uns après les autres lors de la phase d'apprentissage afin d'apprendre.

Vous pouvez considérer les instances des entrées comme des "questions" et les valeurs "cibles" comme des "réponses". Ainsi, à chaque fois qu'un couple d'entrée-cible est présenté au réseau de neurones, ce dernier connaît la réponse pour une question donnée. Il n'en demeure pas moins qu'à chaque instance, le réseau de neurones doit faire une supposition à l'aide des valeurs actuelles des poids, et ses performances sont alors testées en utilisant un critère connu sous le nom de fonction d'erreur. Si la performance n'est pas adéquate, les poids du réseau sont alors ajustés afin de produire une réponse exacte (ou du moins, plus exacte) par rapport à la précédente tentative. D'une manière générale, ce processus d'apprentissage intègre un certain bruitage (c'est-à-dire que les réponses du réseau peuvent être parfois plus exactes lors du cycle précédent de l'apprentissage par rapport au cycle actuel), mais en moyenne, l'importance des erreurs s'amenuise à mesure que l'apprentissage du réseau progresse. L'ajustement des poids s'effectue par le biais d'un algorithme d'apprentissage, qui comme un professeur, va apprendre au réseau de neurones à choisir ses poids afin d'obtenir de meilleures prévisions pour chacun des couples d'exemples entrée-cible du fichier de données.

Les étapes ci-dessus constituent l'apprentissage. Du point de vue des calculs, il repose sur la série d'étapes ci-dessous :

1. Présenter au réseau un couple entrée-cible.
2. Calculer les prévisions du réseau pour les cibles.
3. Utiliser la fonction d'erreur pour calculer la différence entre les prévisions (sorties) du réseau et les valeurs cible. Reprendre les étapes : 1 et 2 jusqu'à ce que tous les couples entrée-cible aient été présentés au réseau.
4. Utiliser l'algorithme d'apprentissage afin d'ajuster les poids du réseau de telle sorte qu'il produise de meilleures prévisions à chaque couple entrée-cible.
5. Répéter à nouveau les étapes 1 à 5 pendant un certain nombre de cycles d'apprentissage ou d'itérations jusqu'à ce que le réseau commence à produire des résultats suffisamment fiables (c'est-à-dire des sorties qui se trouvent assez proches des cibles compte tenu des valeurs d'entrée). Un processus d'apprentissage type pour les réseaux de neurones est constitué de plusieurs centaines de cycles.

Remarque : les étapes 1 à 5 constituent un seul cycle d'apprentissage ou itération. Le nombre de cycles nécessaire pour entraîner un modèle de réseaux de neurones n'est pas connu a priori mais peut être défini dans le cadre du processus d'apprentissage.

II.3.11. La Fonction d'Erreur :

Comme indiqué précédemment, la fonction d'erreur permet d'évaluer la performance d'un réseau de neurones au cours de l'apprentissage. Vous pouvez considérer qu'il s'agit d'un examinateur qui évalue les performances d'un étudiant. La fonction d'erreur indique dans quelle mesure les prévisions du réseau sont proches des valeurs cible et donc, quel ajustement doit être apporté aux poids par l'algorithme d'apprentissage à chaque itération. La fonction d'erreur représente donc d'une certaine manière les yeux et les oreilles de l'algorithme d'apprentissage pour savoir si le réseau est performant ou non compte tenu de l'état actuel de l'apprentissage (et donc, quel ajustement doit être apporté aux valeurs de ses poids).

Toutes les fonctions d'erreur utilisées pour l'apprentissage des réseaux de neurones doivent intégrer une certaine mesure des distances entre les valeurs cible et les prévisions correspondant

aux entrées. Une approche courante consiste à utiliser la fonction d'erreur dite de somme des carrés. Dans ce cas, le réseau va apprendre une fonction discriminante. L'erreur de la somme des carrés est simplement donnée par la somme des différences entre les valeurs cibles et les sorties prévues définies pour l'ensemble d'apprentissage. Ainsi :

$$E_{SC} = \sum_{i=1}^N (y_i - t_i)^2$$

N représente le nombre d'observations d'apprentissage, y_i représente la prévision (sortie du réseau) et t_i représente de la valeur cible pour la i ème observation. Plus la différence entre les prévisions du réseau et les valeurs cible sera importante, plus la valeur de l'erreur sera grande, ce qui nécessite alors un ajustement plus important des poids par l'algorithme d'apprentissage. La fonction d'erreur de la somme des carrés s'utilise essentiellement dans les problématiques de régression mais elle peut également s'utiliser pour des tâches de classification. Toutefois, pour réaliser une véritable classification par les réseaux de neurones, il faut utiliser une autre fonction d'erreur que la somme des carrés, c'est-à-dire la fonction d'erreur de l'entropie croisée. C'est grâce à cette fonction d'erreur combinée à la fonction d'activation des sorties soft max que nous pouvons interpréter les sorties d'un réseau de neurones sous la forme de probabilités d'appartenance des individus à une classe.

La fonction d'erreur d'entropie croisée est donnée par la formule suivante :

Qui considère que les variables cible suivent une distribution multinomiale. Au contraire, l'erreur de la somme des carrés va modéliser la distribution des valeurs cible comme une fonction de densité de probabilités normale.

Remarques : l'erreur d'apprentissage de la régression se calcule à partir de l'erreur de la somme des carrés définie sur l'ensemble d'apprentissage. Les calculs sont réalisés en utilisant les valeurs cible transformées (ramenés sur un intervalle de 0 à 1). De la même manière, la mesure des erreurs de test et de validation se définit comme la somme des carrés des erreurs individuelles définie respectivement sur les échantillons de test et de validation.

$$E_{SC} = - \sum_{i=1}^N t_i \ln\left(\frac{y_i}{t_i}\right)$$

II.3.12. L'Algorithme d'Apprentissage :

Les réseaux de neurones sont des outils fortement non-linéaires qui utilisent généralement des techniques itératives pour l'apprentissage. Les techniques les plus conseillées pour l'apprentissage des réseaux de neurones sont les algorithmes BFGS (Broyden-Fletcher-Goldfarb-Shanno) et SCD (Scaled Conjugate Gradient) une amélioration subtile des gradients conjugués, permettant de supprimer la minimisation unidimensionnelle, (Bishop, 1995). Ces méthodes fournissent généralement de meilleurs résultats que les algorithmes plus classiques comme la Descente de Gradient mais ils sont également généralement plus gourmands en termes de mémoire et nécessitent davantage de calculs. Ces techniques peuvent toutefois nécessiter moins d'itérations pour l'apprentissage d'un réseau de neurones compte tenu de leur taux de convergence rapide et d'un critère de recherche plus intelligent. (**Khayet M , 2011**)

- L'Apprentissage des Réseaux de Neurones Perceptrons Multicouches:

Un certain nombre d'options pour l'apprentissage des réseaux de neurones PMC est proposé. Parmi celle-ci, les méthodes BFGS (Broyden-Fletcher-Goldfarb-Shanno), SCG (Scaled Conjugate Gradient), la Descente de Gradient et Levenberg-Marquardt (L-M).

II.3.13. Généralisation du Réseau:

- **Généralisation et Performance :**

La performance des réseaux de neurones se mesure par la manière dont ils savent prévoir des données inconnues (un ensemble de données inconnues est un ensemble de données n'ayant pas été utilisé lors de la phase d'apprentissage). Ce processus est connu comme la généralisation. La question de la généralisation est en fait une question majeure qui se pose lors de l'apprentissage des réseaux de neurones. Ce phénomène s'exprime par une tendance au sur-ajustement des données d'apprentissage s'accompagnant d'une difficulté à prévoir de nouvelles données. Même s'il est toujours possible de trouver (sur-ajuster) un réseau de neurones suffisamment complexe et flexible en mesure de produire un ajustement parfait (c'est-à-dire avec une erreur d'apprentissage nulle), le véritable problème consiste à réussir à construire un réseau capable également de bien prévoir les nouvelles données. En définitive, il existe une relation entre le sur-ajustement des données d'apprentissage et le mauvais pouvoir de généralisation. Par conséquent, lors de l'apprentissage des réseaux de neurones, nous devons toujours tenir compte des questions de

performance et de généralisation. (Al-shayji K.A 2002)

- **Données de Test et Interruption Prématuration :**

Différentes techniques permettent de lutter contre le problème de sur-ajustement en apportant une réponse au problème de la généralisation. La plus courante consiste à utiliser des données de test. Les données de test sont en fait un échantillon de réserve qui n'est jamais utilisé pour l'apprentissage. Il est en revanche utilisé pour valider la manière dont un réseau se comporte pour modéliser la relation entre les entrées et les valeurs cible à mesure que l'apprentissage progresse. L'essentiel du travail permettant d'évaluer les performances en modélisation neuronale repose sur les différentes approches des données de test. L'optimisation d'un réseau de neurones s'effectue à l'aide d'un ensemble d'apprentissage. Un ensemble de test distinct est ensuite utilisé pour interrompre l'apprentissage afin de limiter le phénomène de sur-ajustement. Le processus d'interruption de l'apprentissage du réseau de neurones en vue d'éviter le sur-ajustement et d'améliorer le pouvoir de généralisation est connu sous le nom d'interruption prématurée (early-stopping). Cette technique modifie sensiblement l'algorithme d'apprentissage afin de:

1. Présenter au réseau un couple de valeurs entrées-cible issu de l'ensemble d'apprentissage.
2. Calculer les prévisions du réseau pour les valeurs cible.
3. Utiliser la fonction d'erreur pour calculer la différence entre les prévisions (sorties) du réseau et les valeurs cible.
4. Continuer avec les étapes : 1 et 2, jusqu'à ce que tous les couples de valeurs entrées-cible de l'ensemble d'apprentissage aient été présentés au réseau.
5. Utiliser l'algorithme d'apprentissage pour ajuster les poids du réseau afin d'améliorer les prévisions pour toutes les valeurs entrée-cible.
6. Envoyer l'ensemble du jeu de test au réseau, effectuer les prévisions, et calculer la valeur de l'erreur de test du réseau.
7. Comparer l'erreur de test à celle de l'itération précédente. Si l'erreur continue de diminuer, l'apprentissage se poursuit ; dans le cas contraire, l'apprentissage prend fin.

Remarque : le nombre de cycles nécessaires pour l'apprentissage d'un modèle de réseau de neurones avec des données de test et un arrêt prématuré peut varier. En théorie, nous devons poursuivre l'apprentissage de réseau pendant autant de cycles que nécessaire, tant que l'erreur de test diminue.

Nous poursuivons l'apprentissage du réseau de neurones pendant un certain nombre de cycles tant que l'erreur de test continue à diminuer. Dès que l'erreur de test commence à augmenter, l'apprentissage prend fin.

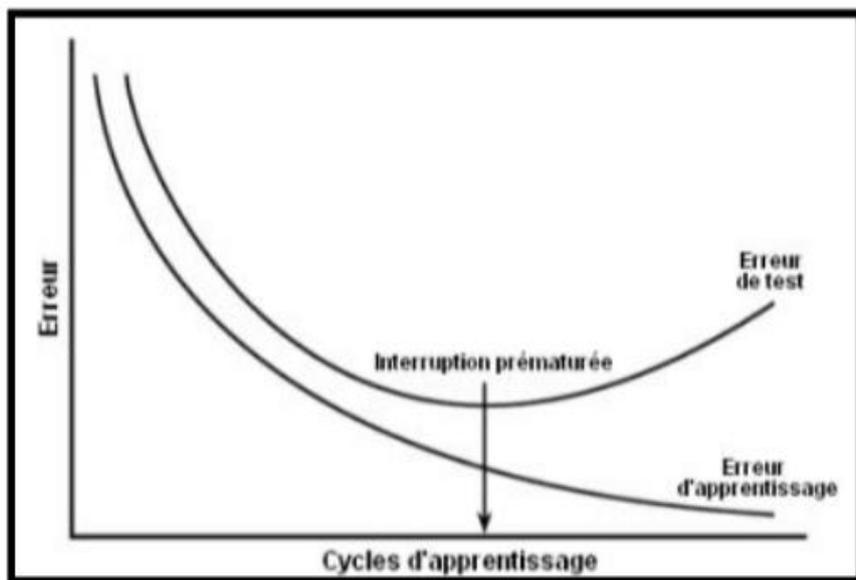


Figure II.5. Schéma de l'apprentissage d'un réseau de neurones avec interruption prématurée

II.3.14. Données de Validation :

Parfois, les données de test seules peuvent ne pas apporter une preuve suffisante du bon pouvoir de généralisation d'un réseau de neurones entraîné. Par exemple, il est tout à fait concevable qu'une bonne performance sur l'échantillon de test soit juste le fruit du hasard. Pour nous assurer que ce n'est pas le cas, nous recourons souvent à un autre jeu de données connu sous le nom d'échantillon de validation. Tout comme l'échantillon de test, l'échantillon de validation n'est jamais utilisé pour l'apprentissage du réseau de neurones. Nous l'utilisons en

revanche à l'issue de l'apprentissage comme une vérification supplémentaire de la performance du modèle. Si la performance du réseau est tout à fait correcte à la fois sur l'échantillon de test et sur l'échantillon de validation, nous pouvons raisonnablement considérer que le réseau possède un bon pouvoir de généralisation sur des données inconnues. (**Hamadache , 2014**)

II.3.15. Transformation et Traitement a Posteriori des Données :

Tous les neurones d'un réseau de neurones utilisent des entrées numériques et produisent des sorties numériques. La fonction d'activation d'une unité neuronale peut accepter des valeurs d'entrée de n'importe quel ordre de grandeur et produire des sorties dans un intervalle limité strictement. Bien que les entrées puissent se situer dans n'importe quel ordre de grandeur, il existe un effet de saturation qui fait que l'unité n'est sensible qu'à des entrées situées dans un intervalle relativement limité. Par exemple, considérons une fonction logistique. Dans ce cas, la sortie est dans l'intervalle (0,1), et l'entrée n'est sensible que dans un intervalle guère plus large que (-1, +1). Par conséquent, pour un vaste intervalle de valeurs d'entrées situées en dehors de l'intervalle (-1, +1), la sortie d'un neurone logistique est sensiblement la même. Cet effet de saturation va sévèrement limiter la possibilité d'un réseau à capturer la relation entrées-cibles sous-jacente.

Nous pouvons résoudre le problème ci-dessus en limitant l'intervalle numérique des entrées originales et des variables cible. Ce processus est connu sous le nom de réduction, qui constitue l'une des formes les plus répandues de transformation des données. Les variables d'entrée et les variables cible sont réduits à l'aide de transformations linéaires de sorte que les valeurs originales minimum et maximum de chacune des variables soit projetées dans un intervalle (0, 1).

Mais il existe également d'autres raisons importantes de standardiser les variables. Parmi celles-ci, citons la modération des poids. La standardisation des entrées et des cibles va généralement permettre de rendre plus efficace la régularisation de modération des poids. Mais nous pouvons également citer comme autre justification à la standardisation des variables, l'échelle originale des variables et les unités de mesures utilisées. Les variables du fichier de données original possèdent fréquemment des ordres de grandeur différents (c'est-à-dire qu'elles possèdent des variances différentes). La raison peut résider dans l'utilisation d'unités de mesure différentes ou simplement tenir à la nature même des variables. Il est clair que l'étendue

numérique d'une variable particulière parmi d'autres, n'est pas nécessairement un bon indicateur de l'importance de cette variable. (Al-shayji K.A 2002)

II.3.16. Préviation des Données Futures :

Vous pouvez utiliser un réseau de neurones déjà entraîné pour réaliser des prévisions sur de nouvelles données avec des variables ayant été générées par les mêmes processus et relations sous-jacentes que le jeu de données original qui a été utilisé pour l'apprentissage du modèle. La possibilité de généraliser est une caractéristique essentielle des réseaux de neurones, et le processus qui consiste à utiliser des réseaux de neurones pour réaliser des prévisions futures est connu sous le nom de déploiement.

Il faut toutefois garder une question importante à l'esprit lorsque vous déployez des modèles de réseaux de neurones. Il ne faut pas chercher à extrapoler, c'est-à-dire introduire dans le modèle de réseau de neurones des valeurs d'entrées qui diffèrent de façon significative de celles qui ont été utilisées pour l'apprentissage du réseau.

III.3.17 Conclusion

Nous avons passé en revue au travers ce chapitre, les principaux notions et vocabulaire de la technique des réseaux de neurone artificiels (RNA), notamment les PMC.

Les étapes de modélisations consistent à :

- Choisir les valeurs d'entrée et définir la cible.
- Choisir le nombre de neurone dans la couche cachée et la fonction d'activation ainsi que l'algorithme d'apprentissage sont des phases primordiales.
- L'ajustement des poids, basé sur la minimisation d'une fonction erreur, en phase de calage ou apprentissage, aboutit à une modélisation satisfaisante en phase de validation et de généralisation.

Chapitre III

**Modélisation des
paramètre liée aux
dessalement d'eau de mer
par RNA**

III.1. Introduction

Le dessalement de l'eau de mer est une solution cruciale pour pallier les pénuries d'eau douce dans de nombreuses régions du monde. Parmi les technologies disponibles on trouve la nanofiltration (NF) et l'osmose inverse (OI) sont particulièrement efficaces mais présentent des défis complexes en termes d'optimisation des paramètres opérationnels pour maximiser l'efficacité et minimiser les coûts. L'utilisation des réseaux de neurones artificiels (RNA) offre une approche prometteuse pour modéliser et prédire les performances de ces systèmes en fonction de divers paramètres.

Au cours de ce chapitre, nous présentons l'ensemble des matériels et des méthodes utilisés pendant la modélisation neuronale des paramètres sensible liées aux processus de dessalement par NF et OI. Nous montrerons les étapes de développement et leurs évolutions, en donnant tout d'abord les résultats préliminaires puis les résultats finaux issus de ces modèles. Nous effectuerons des analyses statistiques afin de tester la performance et l'exactitude de chaque modèle, finalement nous discuterons ces résultats pour arbitrer et valider nos modèles.

Afin de rendre ce chapitre clair et structuré, nous l'avons organisé en trois parties principales :

Dans la première partie, nous expliquerons tous les matériels et méthodes utilisés, notamment les logiciels informatiques, la description de la base de données, leur collection et préparation, la procédure de traitement des paramètres d'entrées pour sélectionner que les pertinents. Nous expliquerons également brièvement la méthodologie utilisée pour le développement de ces modèles et la manière de choisir leurs paramètres. La base de données utilisée dans cette étude comprend 60 expériences, chacune représentant un instantané du processus de dessalement hybride NF/OI/MSF. Les variables mesurées incluent le temps (t), la pression (P), la température (T), le débit d'entrée (Q_{in}), la conductivité de l'eau en entrée (C_{in}), le taux de conversion de perméat (TCp), le débit de perméat (Qp) et la conductivité de l'eau perméat (Cp).

Dans la seconde partie, nous présenterons tous les résultats obtenus durant et après le développement des modèles RNA, en incluant l'architecture des meilleurs modèles obtenus,

ainsi que certaines analyses telles que le calcul des erreurs et l'analyse de sensibilité qui mesure la contribution des variables d'entrée sur les propriétés à modéliser.

Dans la dernière partie de ce chapitre, nous présenterons une conclusion qui résume brièvement le travail et souligne les étapes les plus importantes. Ce chapitre pose ainsi les bases méthodologiques et techniques de la modélisation des processus de dessalement par RNA.

III.2. Matériels et méthodes

III.2.1. Outils informatiques utilisés

Plusieurs logiciels ont été utilisés pendant la réalisation de ce travail, comme ils sont organisés dans la **Figure III.1**, et dans les parties ci-dessous :

- Nous avons utilisé le logiciel "Microsoft Office Excel 2016" pour organiser la base des données et le prétraitement.
- L'apprentissage du modèle neuronal réalisé par le logiciel "STATISTICA Versions 14" [Stat Soft ,2011].
- Nous avons utilisé le logiciel "MATLAB R2020b" (The Mathworks Inc 2013), pour tracer les graphes et calculé les erreurs des modèles développées.

Il convient de noter que tous les calculs d'exécution de ce travail ont été effectués à l'aide des ordinateurs personnelles :

- (1) HP : doté d'un processeur Intel(R) Core(TM) i5-7300U à 2.60 GHz de CPU et de 8Go de mémoire vive (RAM), avec Windows 10 Professionnel comme système d'exploitation.
- (2) Acer : doté d'un processeur pentium (R) Dual Core T4400 à 2.20 GHZ de CPU et de 4 Go de mémoire vive (RAM), avec Windows 7 Professional comme système d'exploitation.



Figure III.1. Capture d'écran des logiciels utilisés dans cette étude : MATLAB, STATISTICA, et Microsoft Office Excel

III.2.2. Méthodologie générale de la modélisation

Plusieurs étapes ont été utilisées dans le développement des modèles de type RNA. Cependant, on peut distinguer deux grandes catégories principales qui sont les plus couramment adoptées.

La première est désignée à la préparation des données qui comprend la collection, organisation et le traitement des données ; comme celle de connaître la nature des corrélations entre les entrées et les sorties. Les dernières étapes sont celle bases sur le choix des paramètres des modèles pour la génération des meilleurs modèles neuronales et en fin mesure de ces performances et la validation. La méthodologie générale de développement suiviez dans ce travail et résumé ci-dessus dans la **Figure III.2**

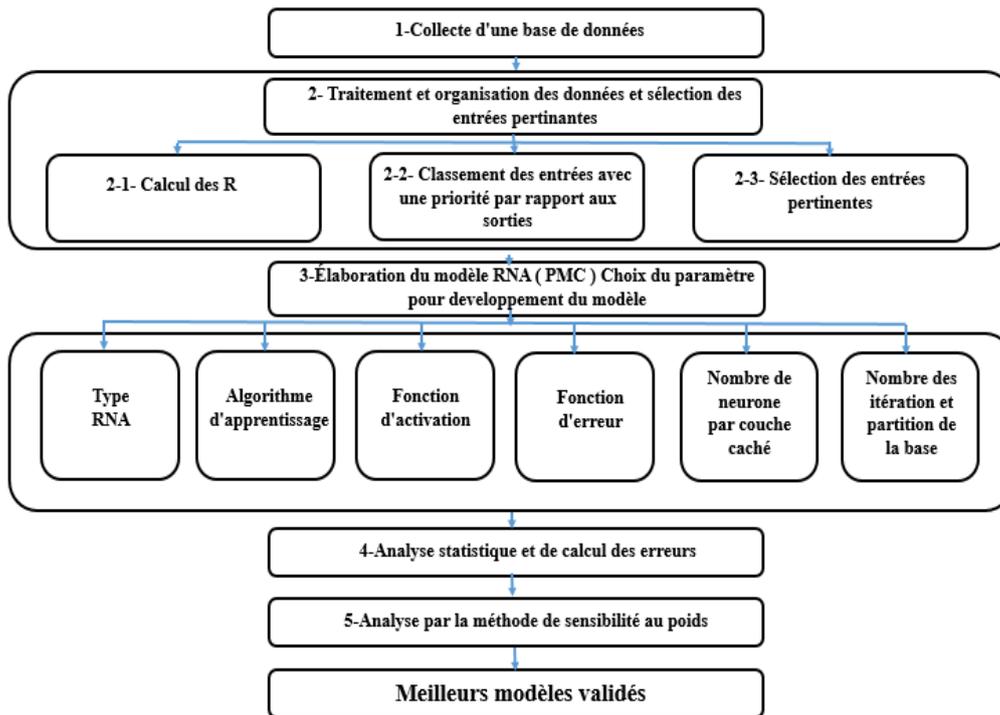


Figure III.2. Organigramme générale décrit la méthodologie de développement suivie dans ce travail.

III.2.2.1. Collection et préparation de la base des données

La base de données comporte 60 expériences, chacun représentant des paramètres liés au processus de dessalement hybride NF/OI/MSF ; qui sont : le temps (t), la pression (P), la température (T), le débit d'entrée (Q_{in}), la conductivité de l'eau en entrée (C_{in}), le taux de conversion de perméat (TCp), le débit de perméat (Qp) et la conductivité de l'eau perméat (Cp).

Ces données sont indispensables pour l'entraînement et la validation des modèles de RNA, l'ensemble des données ont été tirées à partir de la littérature exactement de l'étude de Hamed et ces co-auteurs (**Hamed *et al.* 2009**).

La base de données totale est présentée dans l'**Annexe A** de cette mémoire de fin d'étude. Également leurs champs de variation utilisés pour chaque paramètre sont exposés dans le **tableau III.1**.

Tableau III.1. Paramètres quantitatives et qualitatives de la base des données.

<i>Paramètres</i>	<i>Valeur minimale</i>	<i>Valeur moyen</i>	<i>Valeurs maximale</i>	<i>Nombres des expériences</i>
TC_P (%)	41,093	44,308	45,951	
Q_P (m³/h)	1,288	1,406	1,483	60
C_P (μS/cm)	1039,823	1141,962	1250,000	

III.2.2.2. Traitement et organisation des données

Avant de travailler par la base de donnée il faut tout d'abord faire un petit traitement sur la base, afin de sélectionner que les entrées pertinentes. Pour cela on a suivi les démarches suivantes :

- Calcul des corrélations **R entrée-entrée** et **R entrée-sortie** avec le logiciel **Matlab**.
- Classement des entrées par priorité vis-à-vis aux sorties, par comparaison aux valeurs **R sortie-entrée**.
- Procédure de traitement et sélection des entrées. Dans cette étapes seul les entrées les plus pertinentes qui sont retenus, cependant les entrées possèdent une grande inter corrélation qui se conditionner par la valeur de **R entrée-entrée** $\geq 0,75$ seront éliminer manuelle par le tableau Excel 2016.

III.2.2.3. Élaboration du modèle RNA

Après le traitement des paramètres d'entées, on obtenir quatre paramètres pour (**Q_P**, **C_P**), et trois pour (**TC_P**) afin de les utilisées comme entrées dans la phase de construction des modèles de RNA. Le choix des paramètres liées aux RNA est un autre défi, car il existe un grand nombre de ces paramètres. En conséquents différents option de choix ont été adapté afin d'obtenir les meilleurs modèles de RNA pour chaque paramètre

Le choix des paramètres de RNA se fait à base des études précédente (**Roubehie fissa et al. 2019**), et par apport la disponibilité des paramètres sur le logiciel utilisé "STATISTICA", donc on va suivre ces étapes :

- L'ensemble de données a été divisé au hasard en trois partions : la première contient 70% pour la phase d'apprentissage et 30% pour la phase de test, puis la deuxième de la

même façon avec 80% et 20%, et finalement la troisième avec 90% et 10% pour les phases d'apprentissage et de test ; respectivement comme montrées dans la **Figure III.3**.

- Le type de RNA utilisé dans ce travail est un perceptron multicouche (PMC), car il est l'un des réseaux de neurones les plus utilisés pour des problèmes d'approximation et de prédiction.
- L'algorithme Quasi Newton à propagation en arrière (*Quasi Newton back propagation algorithm*, plus précisément : *Broyden-Fletcher-Goldfarb-Shanno algorithm BFGS*) a été utilisé comme un algorithme d'apprentissage (**Wessel & Jurs 1994**).
- Cinq fonctions d'activation différents sont utilisées pour chaque couche cachée et sortie. Par conséquent, à la fin de l'exécution, le logiciel donne la meilleure combinaison possible entre les deux fonctions d'activation de la couche concernée la **Figure III.4** montrent la manière de choix dans le logiciel STATISTICA.
- La somme des carrés (*Sum of Squares SOS*) a été choisi en tant que fonction d'erreur.
- Une seule couche cachée est utilisée dans ce travail, avec un changement de 2 à 20 neurones dans cette couche, afin de d'assurer que les variables des modèles de réseaux de neurones ne dépassent pas la taille de la base des données.
- L'exécutions se fait par trois collection différentes pour chaque partition et pour chaque paramètre. De manière ou effectuer 2000, 4000 et 6000 itérations afin d'obtenir les meilleurs modèles de type RNA.

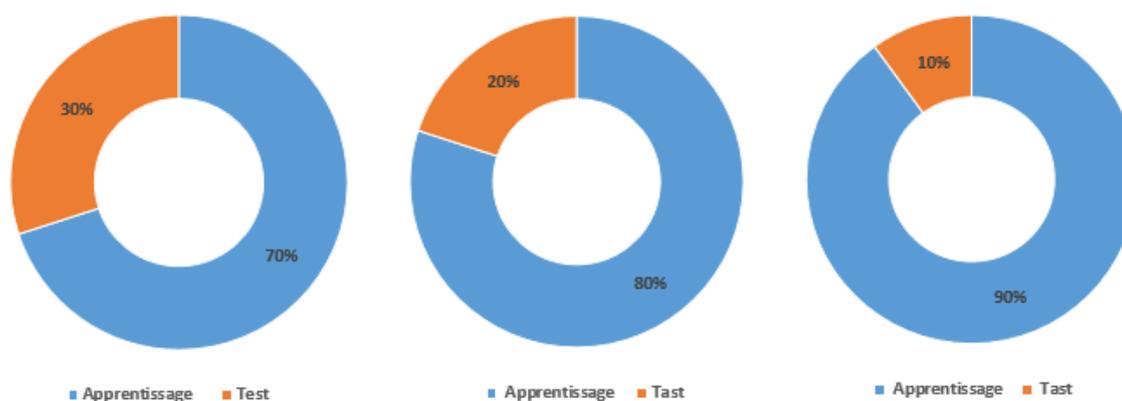


Figure III.3. Représentation graphique des divisions de la base des données.

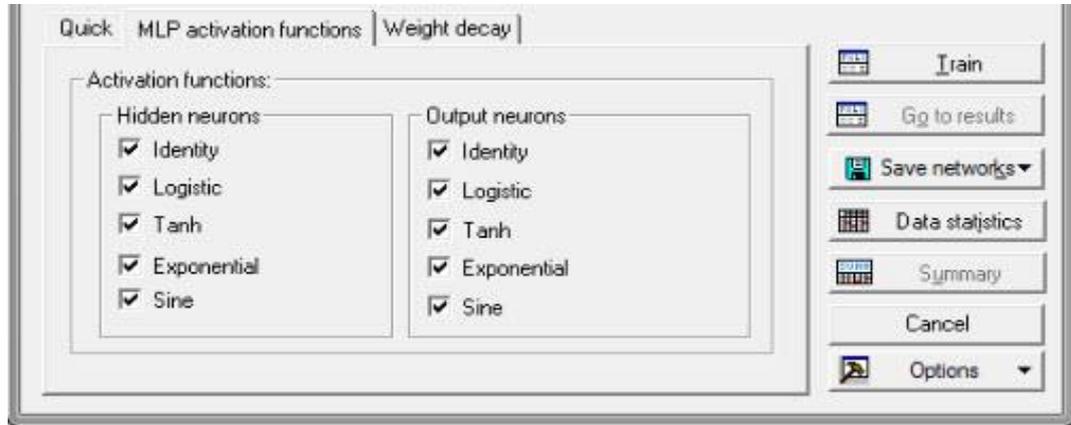


Figure III.4. Capture d'écran pour le choix des fonctions d'activation sur STATISTICA.

III.2.2.4. Analyses statistiques et calculs des erreurs des meilleurs modèles développés

Les performances et la précision des meilleurs modèles de réseaux de neurones artificiels (RNA) obtenus dans cette étude ont été mesurés en fonction de quatre types d'erreurs distinctes : la racine de l'erreur quadratique moyenne (REQM), l'erreur standard de prédiction (ESP), l'erreur relative moyenne (ERM) et l'erreur relative absolue moyenne (ERAM). De plus, les performances de régression ont également été testées à l'aide des coefficients de régression (R) et de détermination (R^2), ainsi que du vecteur de régression, incluant les valeurs de la pente (α) et de l'ordonnée à l'origine (β). Cette évaluation a été réalisée sur l'ensemble des données de test, d'apprentissage et sur les données globales de la base. Les définitions mathématiques des paramètres de la performance sont fournies par les Équations (IV.1–IV.6), respectivement.

$$REQM = \sqrt{\sum_{i=1}^N (y_i^{exp} - y_i^{cal})^2 / N} \quad (III.01)$$

$$ESP = (REQM / \hat{y}^{exp}) * 100 \quad (III.02)$$

$$ERM = \left(\frac{100}{N}\right) * \sum_{i=1}^N (|y_i^{exp} - y_i^{cal}| / y_i^{cal}) \quad (III.03)$$

$$ERAM = \left(\frac{100}{N}\right) * \sum_{i=1}^N (|(y_i^{exp} - y_i^{cal}) / y_i^{exp}|) \quad (III.04)$$

$$R = \frac{\sum_i^N [(y_i^{exp} - \hat{y}^{exp})(y_i^{cal} - \hat{y}^{cal})]}{\sqrt{\sum_{i=1}^N (y_i^{exp} - \hat{y}^{exp})^2} \sqrt{\sum_{i=1}^N (y_i^{cal} - \hat{y}^{cal})^2}} \quad (\text{III.05})$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i^{exp} - y_i^{cal})^2}{\sum_{i=1}^N (y_i^{exp} - \hat{y}^{exp})^2} \quad (\text{III.06})$$

$$\hat{y}^{exp} = \frac{\sum_{i=1}^N y_i^{exp}}{N} \quad (\text{III.07})$$

Où N est le nombre des composés dans l'ensemble des données pour chaque phase : (apprentissage, test ou l'ensemble entière des données), y^{cal} est la valeur calculée (prédite) de y ; pour l'ensemble d'apprentissage de test , y^{exp} est la valeur expérimentale (observée) de y , et \hat{y}^{exp} la moyenne des valeurs expérimentales de y ; (Eq (III.07)).

III.2.2.5. Mesure de la contribution relative des entrées des modèles RNA développées

L'analyse de sensibilité est un outil crucial pour l'évaluation des modèles mathématiques. Elle sert à plusieurs fins, notamment la validation du modèle, l'évaluation du comportement des différentes variables et la confirmation du choix des variables en déterminant la contribution de chacune d'elles. Par conséquent, il est essentiel d'appliquer cette analyse aux modèles de type RNA (Roubehie fissa et al. 2019).

Dans cette étude l'analyse de sensibilité par la méthode de "Poids" (Weights method) a été utilisée, afin d'évaluer l'impact de la contribution de toute variable d'entrée dans notre cas sont les paramètres d'entrée pertinents de chaque modèle (t , P , T , Q_{in} , C_{in}) sur les sorties (les trois paramètres de sortie : TC_P , Q_P et C_P) de chaque modèle RNA. Cette analyse est aussi importante pour confirmer notre choix des paramètres utilisés dans le développement des modèles de type RNA, et donc l'efficacité de la méthode de prétraitement adaptée.

La méthode utilisée dans cette étude (méthode de Poids) ; a été organisée et programmée dans un tableur "Microsoft Excel", en suivant les étapes théoriques indiquées dans l'étude de Gevrey et ses co-auteurs (Gevrey et al. 2003). Comme l'indique le nom de la méthode "Poids", on introduit les poids de connexion de partitionnement en : (1) Poids de la couche entrée (w_{ij}^I)

(connexions entre les neurones d'entrée et cachés), (2) Poids de la couche cachée (w_{1j}^H) (connexions entre les neurones cachés et de sortie). Pour trouver, à la fin une signification quantifiée de chaque paramètre d'entrée sur chaque sortie du modèle, ce qui se traduit par l'importance relative (*IR*) de chaque paramètre (Khaouane 2013 ; Roubehie fissa *et al.* 2019).

Pour mieux comprendre cette méthode, nous nous référons à l'exemple présenté dans l'étude de Goh (Goh 1995), et ainsi qu'à celle de Gevrey et ses co-auteurs (Gevrey *et al.* 2003) . La procédure de calcul de cette méthode est également illustrée par l'organigramme de la figure III.6 (Khaouane 2013).

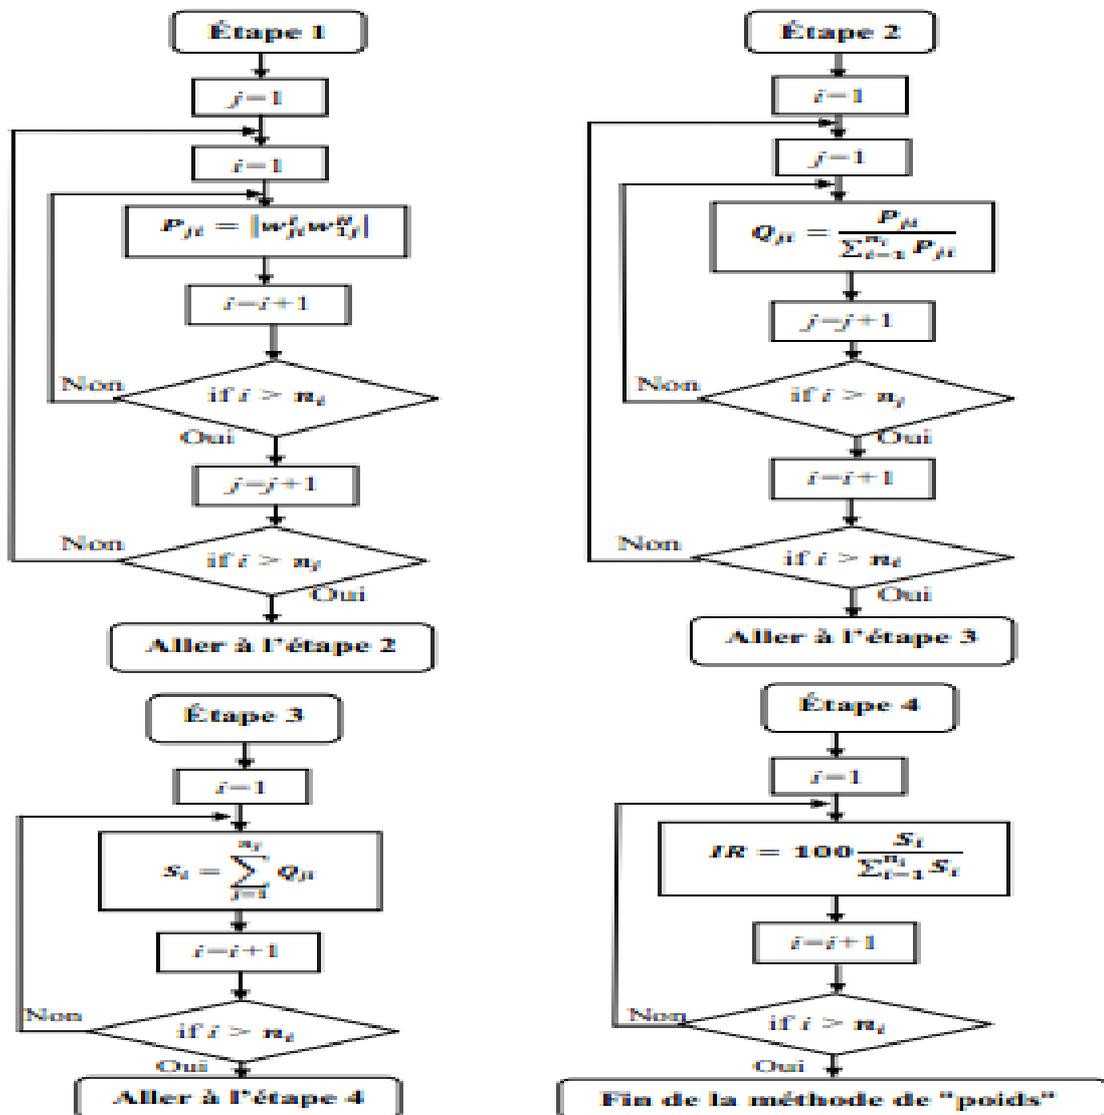


Figure III.5. Organigramme illustrant l'analyse de sensibilité par la méthode de la partition des poids (méthode de poids) (**Khaouane 2013**).

III.3. Résultats et discussions

III.3.1. Résultats d'organisation de la base et sélection des entres pertinentes

L'étape de sélection des entrées pertinentes est cruciale pour garantir la précision et l'efficacité des modèles de réseaux de neurones utilisés dans les processus de dessalement. Cette étape repose sur une analyse de corrélation croisée entre les paramètres d'entrée et les variables de sortie.

Tout d'abord, une analyse de la corrélation croisée est effectuée entre chaque paramètre d'entrée et les variables de sortie afin de déterminer les relations significatives. Les paramètres d'entrée qui montrent une forte corrélation entre eux ($R > 0.75$) sont éliminés pour éviter la multicollinéarité, à moins que leur relation avec les variables de sortie ne soit significative.

Les résultats de l'analyse de la corrélation sont présentés dans le tableau (**III.02**), qui montre les coefficients de corrélation entre les paramètres d'entrée et de sortie. Ce tableau aide à comprendre quels paramètres sont les plus pertinents et lesquels doivent être supprimés en raison de leur haute inter-corrélation. Par exemple, les paramètres faiblement corrélés entre eux mais fortement corrélés avec les variables de sortie sont retenus, tandis que ceux avec une corrélation élevée entre eux sont éliminés manuellement, sauf s'ils sont essentiels.

Tableau III.02. Coefficients de corrélation des paramètres d'entrées et de sorties.

Matrice des coefficients de corrélation des paramètres d'entrées					Vecteurs des coefficients de corrélation des paramètres de sorties		
t (h)	P (bar)	T (C°)	Q _{inP} (m ³ /h)	C _{inP} (μS /cm)	TC _P (%)	Q _P (m ³ /h)	C _P (μS /cm)
1	0,8250	0,6696	0,2736	0,5791	0,3468	0,6434	0,4017
0,8250	1	0,9047	0,2191	0,6425	0,3917	0,5387	0,5549
0,6696	0,9047	1	0,0357	0,5524	0,2719	0,4495	0,5699
0,2736	0,2191	0,0357	1	0,1101	0,4304	0,3461	0,0540
0,5791	0,6425	0,5524	0,1101	1	0,3936	0,4532	0,3394

III.3.2. Résultats d'exécution des modèles neuronales des paramètres liés aux dessalement de l'eau de mer

Après la sélection des paramètres liés au modèle de RNA à été mentionné dans la partie matériel et méthode (III.2.2.3). Les résultats des exécutions des modèles de réseaux de neurones artificiels (RNA) pour les paramètres liés au dessalement de l'eau de mer sont présentés en termes de performances des modèles sur différents ensembles de données (apprentissage et test). Voici les principaux résultats présentés sous forme de tableau (III.03, III.04, III.05) pour les trois paramètres TC_P, Q_P et C_P.

Ces tableaux résumés les performances des 9 modèles de réseaux de neurones pour les différents paramètres du dessalement de l'eau de mer, en fonction de différentes divisions des ensembles de données, itérations, architectures et fonctions d'activation utilisées.

Les résultats montrent que les modèles de RNA ont été capables de prédire les paramètres de dessalement avec un bon degré de précision, comme en témoignent les coefficients de régression élevés (R et R²) et les faibles sommes des carrés (SOS) des erreurs, notamment pour les ensembles de données de test. Les différentes architectures et fonctions

d'activation testées ont permis d'identifier les configurations optimales pour chaque paramètre.

Division	Itérations	Architecture du RNA	Fonctions d'activation (Entrée-Caché) / (Caché-Sortie)	R_{App}	R_{Test}	SOS_{App}	SOS_{Test}	Algorithme d'apprentissage
70%/30%	2000	03-20-01	Logistic/ Logistic	0,7787	0,9211	0,2031	0,0932	BFGS 35
	4000	03-17-01	Tanh/ Exponential	0,8811	0,9284	0,1275	0,0755	BFGS 35
	6000	03-15-01	Tanh/ Exponential	0,8266	0,9323	0,1649	0,1008	BFGS 56
80%/20%	2000	03-13-01	Exponential/ Logistic	0,8928	0,9049	0,1169	0,1427	BFGS 41
	4000	03-12-01	Tanh/ Exponential	0,8111	0,9105	0,1910	0,1193	BFGS 22
	6000	03-12-01	Tanh/ Exponential	0,8289	0,9132	0,1749	0,0994	BFGS 46
90%/10%	2000	03-07-01	Logistic/ Logistic	0,8128	0,9716	0,1793	0,0773	BFGS 29
	4000	03-08-01	Logistic/ Tanh	0,9333	0,9356	0,0713	0,1380	BFGS 107
	6000	03-13-01	Exponential/ Tanh	0,9397	0,8945	0,0639	0,1407	BFGS 115

Tableau III.03. Résultats d'exécutions des modèles de RNA pour le taux convention du perméat TC_P (%).

Division	Itérations	Architecture du RNA	Fonctions d'activation (Entrée-Caché) / (Caché-Sortie)	R_{App}	R_{Test}	SOS_{App}	SOS_{Test}	Algorithme d'apprentissage
70%/30%	2000	04-14-01	Exponential / Exponential	0,7877	0,8761	0,0003	0,0002	BFGS 19
	4000	04-16-01	Tanh/ Logistic	0,8538	0,8619	0,0002	0,0002	BFGS 42
	6000	04-13-01	Logistic / Exponential	0,8737	0,8757	0,0002	0,0002	BFGS 55
80%/20%	2000	04-18-01	Tanh/ Logistic	0,9130	0,8317	0,0001	0,0002	BFGS 51
	4000	04-06-01	Identity/ Exponential	-0,0298	0,8513	0,0009	0,0006	BFGS 01
	6000	04-12-01	Tanh/ Logistic	0,8668	0,8195	0,0002	0,0003	BFGS 40
90%/10%	2000	04-10-01	Logistic/ Tanh	0,8901	0,9550	0,0001	0,0001	BFGS 63
	4000	04-10-01	Exponential / Identity	0,8944	0,9451	0,0001	0,0001	BFGS 101
	6000	04-05-01	Logistic / Exponential	0,8988	0,9700	0,0001	0,0001	BFGS 71

Tableau III.04. Résultats d'exécutions des modèles de RNA pour le débit du perméat Q_P (m³/h).

Division	Itérations	Architecture du RNA	Fonctions d'activation (Entrée-Caché) / (Caché-Sortie)	R _{App}	R _{Test}	SOS _{App}	SOS _{Test}	Algorithme d'apprentissage
70%/30%	2000	04-04-01	Logistic / Exponential	0,8926	0,8428	216,4821	437,6395	BFGS 86
	4000	04-03-01	Tanh/ Exponential	0,7899	0,8352	399,8686	485,8329	BFGS 56
	6000	04-04-01	Tanh/ Exponential	0,9101	0,8724	184,1269	478,1950	BFGS 74
80%/20%	2000	04-17-01	Tanh/ Logistic	0,9450	0,9182	107,8548	267,5357	BFGS 93
	4000	04-05-01	Tanh/ Exponential	0,9012	0,9255	190,4997	232,2153	BFGS 63
	6000	04-04-01	Logistic / Identity	0,7529	0,9056	437,5574	731,7957	BFGS 49
90%/10%	2000	04-10-01	Exponential / Identity	0,8953	0,9759	211,8550	143,9776	BFGS 98
	4000	04-07-01	Exponential / Identity	0,9049	0,9846	193,4888	170,8415	BFGS 115
	6000	04-09-01	Tanh/ Exponential	0,9142	0,9931	175,1526	42,6149	BFGS 133

Tableau III.05. Résultats d'exécutions des modèles de RNA pour la conductivité du perméat C_P (µS /cm).

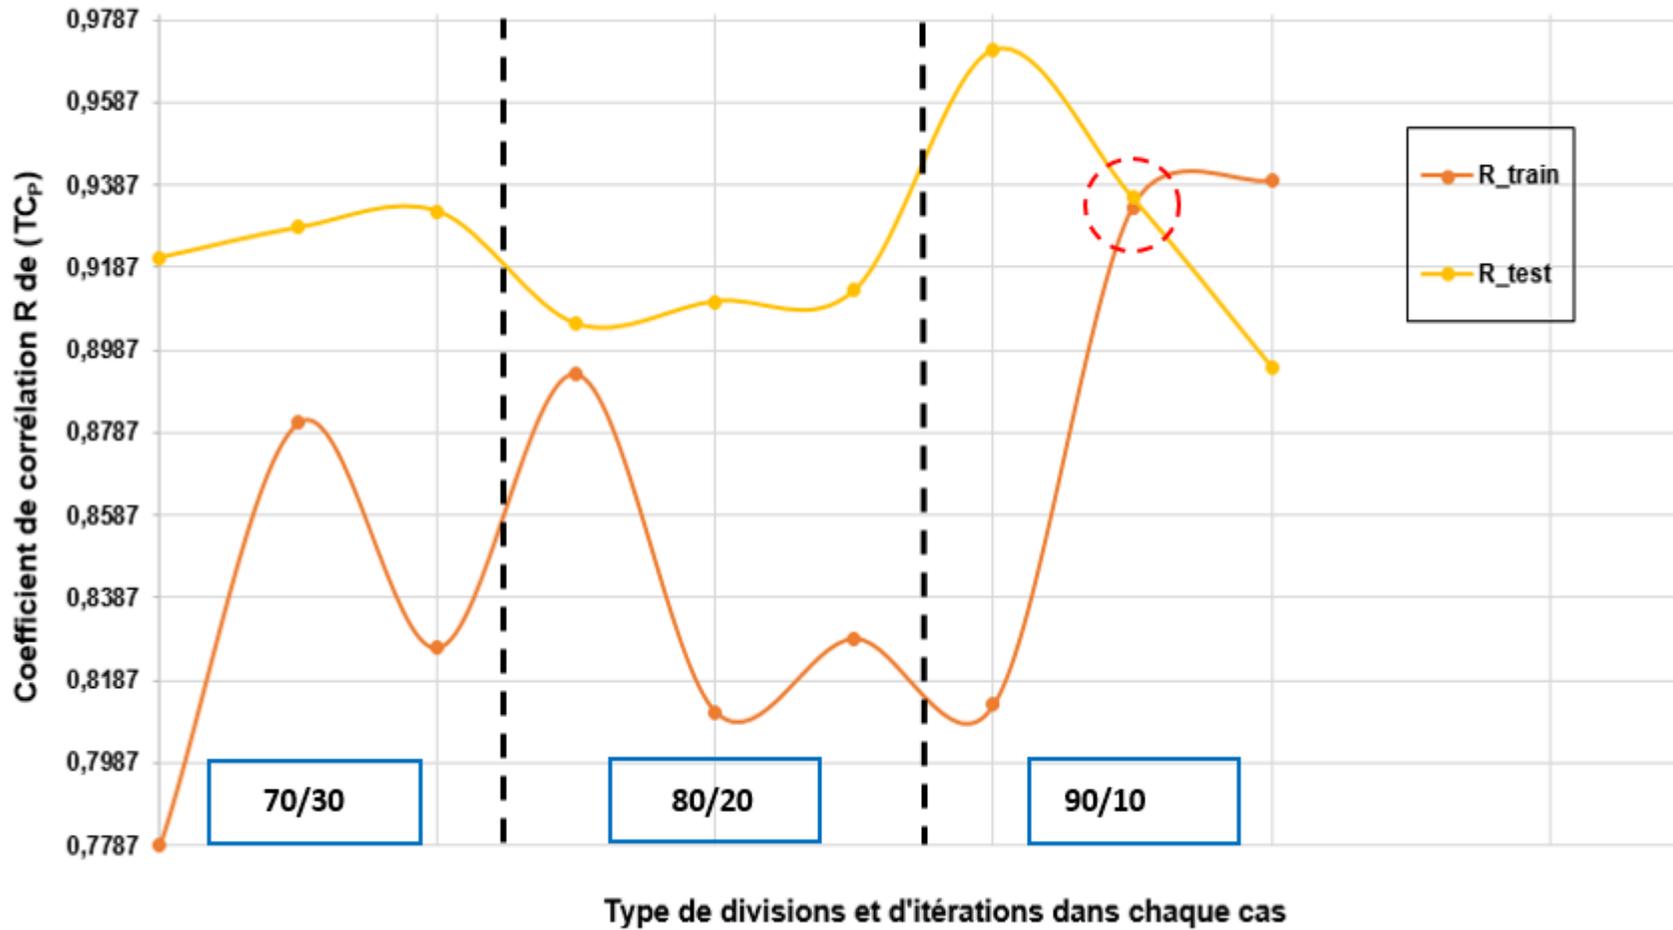


Figure III.6. Evaluation des corrélations des modèles liés au paramètre TC_P selon les divisions et les itérations.

La figure (III.6) montre les coefficients de corrélation (R) pour le taux de conversion du perméat (TC_P) pour différentes divisions de données et itérations. Le meilleur modèle est indiqué dans le cercle rouge et correspond à la division **90/10** des données, avec une architecture de réseau de neurones de type (**03-08-01**) et des fonctions d'activation Logistic/ Tanh.

Le modèle optimal pour la division **90/10** présente un coefficient de régression pour l'ensemble d'apprentissage (R_{App}) de 0,9333 et pour l'ensemble de test (R_{Test}) de 0,9356. Ces valeurs élevées montrent une bonne correspondance entre les valeurs prédites par le modèle et les valeurs réelles, tant pour les ensembles d'apprentissage que de test.

En termes de performance, les sommes des carrés des erreurs (SOS) pour l'ensemble d'apprentissage (SOS_{App}) et l'ensemble de test (SOS_{Test}) sont raisonnablement faibles, avec des valeurs respectives de 0,0713 et 0,1380. Ces valeurs indiquent que les erreurs de prédiction sont modérées, ce qui confirme la précision du modèle.

En conclusion, le modèle situé dans le cercle rouge du graphique est le meilleur pour prédire le taux de conversion du perméat (TC_P) Avec une division de données de **90/10**, des coefficients de régression élevés et des erreurs de prédiction modérées, ce modèle démontre une excellente capacité prédictive et une bonne généralisation, ce qui le rend idéal pour les applications de dessalement de l'eau de mer.

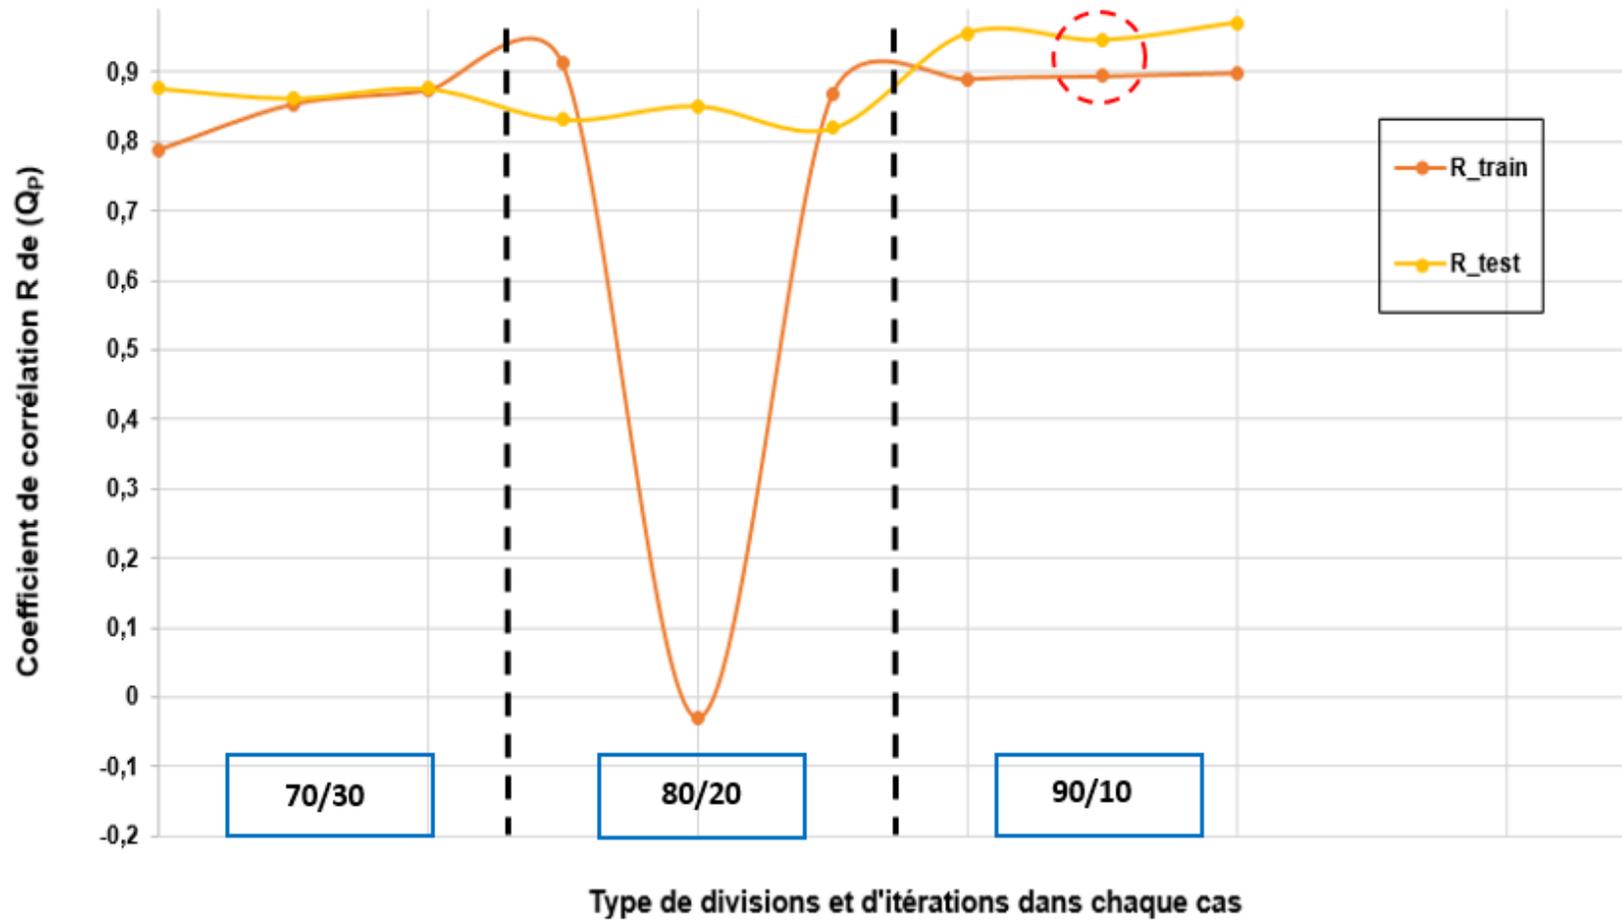


Figure III.7. Evaluation des corrélations des modèles liés au paramètre Q_p selon les divisions et les itérations.

La figure (III.7) montre les coefficients de corrélation (R) pour le débit du perméat (Q_P) pour différentes divisions de données et itérations. Le meilleur modèle est indiqué dans le cercle rouge et correspond à la division **90/10** des données, avec une architecture de réseau de neurones de type **(04-10-01)** et des fonctions d'activation Exponential / Identity.

Le modèle optimal pour la division **90/10** présente un coefficient de régression pour l'ensemble d'apprentissage (R_{App}) de 0,8944 et pour l'ensemble de test (R_{Test}) de 0,9451. Ces valeurs élevées montrent une bonne correspondance entre les valeurs prédites par le modèle et les valeurs réelles, tant pour les ensembles d'apprentissage que de test.

En termes de performance, les sommes des carrés des erreurs (SOS) pour l'ensemble d'apprentissage (SOS_{App}) et l'ensemble de test (SOS_{Test}) sont raisonnablement faibles, avec des valeurs respectives de 0,00017 et 0,00013. Ces valeurs indiquent que les erreurs de prédiction sont modérées, ce qui confirme la précision du modèle.

En conclusion, le modèle situé dans le cercle rouge du graphique est le meilleur pour prédire le débit du perméat (Q_P). Avec une division de données de **90/10**, des coefficients de régression élevés et des erreurs de prédiction modérées, ce modèle démontre une excellente capacité prédictive et une bonne généralisation, ce qui le rend idéal pour les applications de dessalement de l'eau de mer.

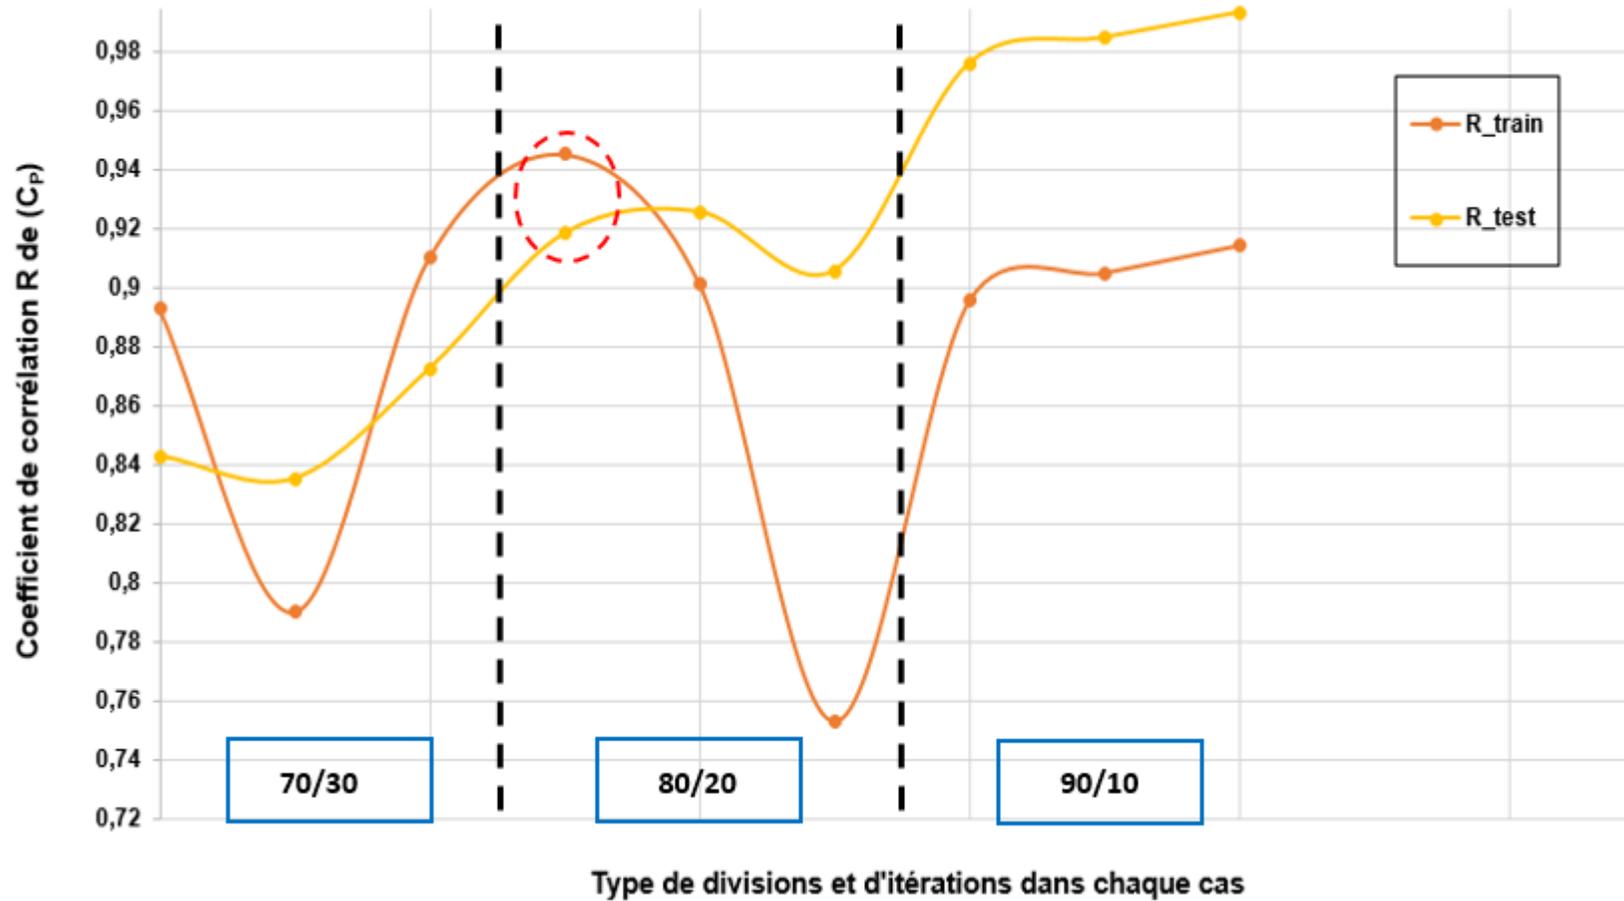


Figure III.8. Evaluation des corrélations des modèles liés au paramètre C_p selon les divisions et les itérations.

La figure (III.8) montre les coefficients de corrélation (R) pour la conductivité du perméat (C_P) pour différentes divisions de données et itérations. Le meilleur modèle est indiqué dans le cercle rouge et correspond à la division **80/20** des données, avec une architecture de réseau de neurones de type **(04-17-01)** et des fonctions d'activation Tanh/Logistic.

Le modèle optimal pour la division **80/20** présente un coefficient de régression pour l'ensemble d'apprentissage (R_{App}) de 0,9450 et pour l'ensemble de test (R_{Test}) de 0,9182. Ces valeurs élevées montrent une bonne correspondance entre les valeurs prédites par le modèle et les valeurs réelles, tant pour les ensembles d'apprentissage que de test.

En termes de performance, les sommes des carrés des erreurs (SOS) pour l'ensemble d'apprentissage (SOS_{App}) et l'ensemble de test (SOS_{Test}) sont très faibles, avec des valeurs respectives de 107,8548 et 267,5357. Ces faibles valeurs de SOS indiquent que les erreurs de prédiction sont minimales, ce qui confirme la précision du modèle.

En conclusion, le modèle situé dans le cercle rouge du graphique est le meilleur pour prédire la conductivité du perméat (C_P). Avec une division de données de **80/20**, des coefficients de régression élevés et des erreurs de prédiction faibles, ce modèle démontre une excellente capacité prédictive et une bonne généralisation, ce qui le rend idéal pour les applications de dessalement de l'eau de mer.

III.3.3. Architectures des meilleurs modèles de RNA obtenus

Après ces étapes de collecte, de réduction, de construction et de calcul, seuls les meilleurs modèles ont été sélectionnés pour tester leurs performances, en calculant Les valeurs de R . Les architectures des meilleurs modèles de RNA obtenus pour chaque paramètre avec certains paramètres statistiques primaires sont représentées dans le **tableau III.06**. Les modèles de RNA possèdent des valeurs de R très élevées ; dans une gamme de 0,93 pour le modèle de TC_P et de (0,94-0,89) pour le modèle Q_P et aussi de (0,94-0,91) pour le modèle de C_P , ceci pour les ensembles de test et d'apprentissage. Les valeurs de SOS sont également faibles une performance élevée des modèles de RNA développés dans cette étude

Comme indiqué dans le **tableau III.06**, les architectures des meilleurs modèles de type de RNA sont (3-8-1) pour le modèle de TC_P , (4-10-1) pour le modèle de Q_P , (4-17-1) pour le modèle de C_P . Les réseaux comportent donc 3, 4 et 4 entrées pour TC_P , Q_P et C_P , respectivement. Avec

une sortie (S) pour chaque modèle. En ce qui concerne les couches cachées, 8, 10 et 17 neurones sont apparus respectivement dans les modèles de : TC_P , Q_P et C_P , respectivement.

Pour les fonctions d'activation, nous avons trouvé en premier lieu, la fonction d'activation tangente hyperbolique "Tanh" deux fois : dans le couche cachée du modèle de C_P , aussi dans le couche sortie du modèle de TC_P . Ensuite, nous avons trouvé également la fonction Sigmoidale Logarithmique "Logistic" deux fois : dans le couche cachée du modèle de TC_P , aussi dans le couche sortie du modèle de C_P . Et en dernier lieu on a trouvé une fois la fonction d'activation exponentielle "Exponential" pour la couche de cachée du modèle de Q_P , et aussi une fois la fonction d'activation Linéaire "Identity" pour la couche de sortie du modèle de Q_P .

Paramètre de sorties	TC_P (%)	Q_P (m³/h)	C_P (μS /cm)
Division	90% / 10%	90% / 10%	80% / 20%
Itérations	4000	4000	2000
Architecture du RNA	03-08-01	04-10-01	04-17-01
Fonctions d'activation (Entrée-Caché) / (Caché-Sortie)	Logistic/ Tanh	Exponential / Identity	Tanh/ Logistic
R_{App}	0,9333	0,8944	0,9450
R_{Test}	0,9356	0,9451	0,9182
SOS_{App}	0,0713	0,00017	107,8548
SOS_{Test}	0,1380	0,00013	267,5357
Algorithme d'apprentissage	BFGS 107	BFGS 101	BFGS 93

Tableau III.06. Architectures des meilleurs modèles de RNA obtenus pour chaque paramètre.

Les définitions mathématiques des fonctions d'activations apparues dans cette étude sont données dans le **tableau III.7** (Voir les **Eqs (III 1), (III 2), (III 3) et (III 4)**) (StatSoft 2007 ; Beale et al. 2012).

Tableau III.7. Fonctions d'activation apparues dans cette étude (StatSoft 2007 ; Beale et al. 2012)

	Fonctions d'activation			
	Exponentielle	Tangent Hyperbolique	Sigmoïde Logarithmique	Linéaire
Notations dans STATISTICA	Exponential	Tanh	Logistic	Identity
Notations dans Matlab	Exp	Tanh	Logsig	Purelin
Formules Mathématiques	$a = e^{-n}$ (III 1)	$a = \frac{e^{+n}-e^{-n}}{e^{+n}+e^{-n}}$ (III 2)	$a = \frac{1}{1+e^{-n}}$ (III 3)	$a = n$ (III 4)
(e): La fonction exponentielle; (n): Les variables des modèles de RNA				

III.3.4. Application des expressions mathématiques des modèles de RNA obtenus

Pour utiliser les modèles de réseaux de neurones artificiels (RNA) développés dans cette étude pour prédire les propriétés critiques du dessalement de l'eau de mer par nanofiltration (NF) et osmose inverse (OI), il est essentiel de comprendre les expressions mathématiques associées à chaque modèle, adaptées spécifiquement à ces processus...

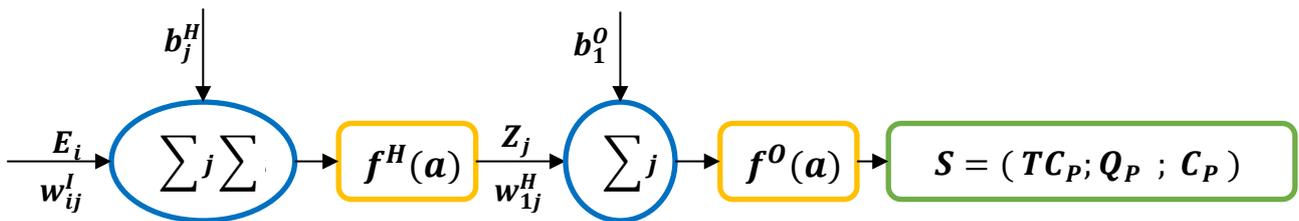


Figure III.9. Représentation schématique d'un réseau du modèle de type RNA.

En plus des explications données sur les architectures des meilleurs modèles de RNA, dans la partie précédente de ce chapitre, l'architecture générale d'un RNA est aussi résumée schématiquement sur la Figure III.9. Tous les modèles sont similaires à ceux représentés dans cette figure, la seule différence résidant dans le nombre de neurones d'entrée, c'est-à-dire les paramètres d'entrée de chaque modèle, et dans le nombre de neurones dans la couche cachée de

chaque modèle. Les expressions mathématiques des sorties (\mathbf{Z}_j) de la couche cachée et (\mathbf{S}) de la couche de sortie de chaque paramètre sont données par les équations ci-après (III.05– III.10) :

$$\mathbf{Z}_j = f^H[\sum_{i=1}^3 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H] = \frac{1}{1+e^{-[\sum_{i=1}^3 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]}} \quad (\text{III.05})$$

$$\mathbf{S} = f^O[\sum_{i=1}^8 \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O] = \frac{e^{+[\sum_{i=1}^8 \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O]} - e^{-[\sum_{i=1}^8 \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O]}}{e^{+[\sum_{i=1}^8 \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O]} + e^{-[\sum_{i=1}^8 \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O]}} \quad (\text{III.06})$$

$$\mathbf{Z}_j = f^H[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H] = e^{-[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]} \quad (\text{III.07})$$

$$\mathbf{S} = f^O[\sum_{i=1}^{10} \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O] = [\sum_{i=1}^{10} \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O] \quad (\text{III.08})$$

$$\mathbf{Z}_j = f^H[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H] = \frac{e^{+[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]} - e^{-[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]}}{e^{+[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]} + e^{-[\sum_{i=1}^4 \mathbf{W}_{ij}^I \mathbf{E}_i + \mathbf{b}_j^H]}} \quad (\text{III.09})$$

$$\mathbf{S} = f^O[\sum_{i=1}^{17} \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O] = \frac{1}{1+e^{-[\sum_{i=1}^{17} \mathbf{W}_{1j}^H \mathbf{Z}_j + \mathbf{b}_1^O]}} \quad (\text{III.10})$$

Chaque neurone caché calcule la fonction d'activation, en envoyant des résultats (\mathbf{Z}_j ; $j = 1$ à 3-4 pour chaque modèle) au neurone de la couche de sortie, qui donne finalement la réponse du réseau (\mathbf{S}). Le signal de sortie de chaque neurone caché (\mathbf{Z}_j) est calculé par les équations : Eq (III.5), Eq (III.7) et Eq (III.9), respectivement pour les modèles de : \mathbf{TCP} , \mathbf{QP} et \mathbf{CP} . Les sorties de chaque réseau sont données par les équations : Eq (III.6) pour le modèle de \mathbf{TCP} Eq (III.8) pour le modèle de \mathbf{QP} , Eq (III.10) pour le modèle de \mathbf{CP} .

Avec f^H la fonction d'activation de la couche cachée (reliant la couche d'entrée avec la couche cachée), f^O la fonction d'activation de la couche de sortie (reliant la couche cachée à la couche de sortie), \mathbf{S} la sortie du réseau (paramètres de sortie : \mathbf{TCP} , \mathbf{QP} et \mathbf{CP}), \mathbf{Z} le signal de sortie des neurones cachés, \mathbf{W}_{ij}^I les poids de la couche d'entrée (connexions entre les neurones d'entrée et cachés), \mathbf{W}_{1j}^H Les poids de la couche cachée (connexions entre les neurones cachés et de sortie), \mathbf{E}_i les neurones d'entrée (dans le cas actuel, les paramètres d'entrée pertinents), \mathbf{b}_j^H sont les biais

de la couche cachée (biais des neurones cachés), b_1^0 est le biais de la couche de sortie (biais du neurone de sortie), i le nombre d'entrées pour chaque modèle ($i = 1 \text{ à } 3$; pour le modèle de TC_P , $i = 1 \text{ à } 4$; pour les modèles de Q_P et C_P), et j est le nombre de neurones cachés ($j = 1 \text{ à } 8$; pour le modèle de TC_P , $j = 1 \text{ à } 10$; pour le modèle de Q_P , $j = 1 \text{ à } 17$; pour le modèle de C_P).

Les relations mathématiques des modèles neuronales finaux pour la prédiction des trois paramètres : TC_P , Q_P et C_P ; lie aux dessalement de l'eau de mer, sont obtenues en utilisant la méthode de RNA-PMC et sont donnés par les Eq (III.6) TC_P , Eq (III.8) pour Q_P et Eq (III.10) pour C_P . Les valeurs des poids (W_{ij}^I, W_{ij}^H) et des biais (b_j^H, b_1^0) des trois meilleurs modèles de RNA pour chaque couche cachée et sortie, sont données respectivement dans : le tableau (III.8) pour le modèle de TC_P , dans le tableau (III.9) pour le modèle de Q_P , dans le tableau (III.10) pour le modèle de C_P .

Tableau III.8. Poids et biais du meilleur modèle de RNA pour TC_P (3-8-1).

Connexion des couches : (Entrée-Caché)				Connexion des couches : (Caché-Sortie)	
Poids			Biais	Poids	Biais
W_{j1}^1	W_{j2}^1	W_{j3}^1	b_j^H	W_{1j}^H	b_1^0
0,1907	1,1855	-8, 8308	3,8974	1,9769	-4,7511
-2, 8811	-1, 5901	-10, 1756	7,9991	1,6444	
11,9628	10,7353	-0, 8673	-5,0064	-0,0007	
-0, 6755	-1, 4087	-3, 7293	1,8738	-8,6964	
0,9711	0,1497	3,1431	-0,0559	0,6971	
2,9970	-4, 6080	2,5493	3,1922	4,7511	
3,1554	-1, 5978	-11, 8357	-3,0068	7,9065	
-5, 8289	-4, 3033	-9, 5479	6,7859	2,1328	

Tableau III.9. Poids et biais du meilleur modèle de RNA pour Q_P (4-10-1).

Connexion des couches : (Entrée-Caché)					Connexion des couches : (Caché-Sortie)	
Poids				Biais	Poids	Biais
W_{j1}^1	W_{j2}^1	W_{j3}^1	W_{j4}^1	b_j^H	W_{1j}^H	b_1^0
-2,0472	5,0525	-1,1450	-5,6997	-0,7509	0,3079	0,2174
-3,0027	2,1288	0,9513	-4,7972	0,0050	-1,2279	
-4,6014	2,4103	2,8392	-4,3924	0,0439	1,1437	
-2,6730	4,1495	0,1027	-2,7357	-0,8826	-0,7318	
-0,4228	0,5829	0,1922	-0,9506	0,4716	0,4822	
-3,5962	0,3326	3,4307	-1,5959	0,1138	-0,3361	
-4,9582	-0,3558	5,3025	-8,7892	0,1250	-1,2265	
-5,0767	-0,5507	3,0531	-3,5599	-0,4682	1,7820	
-2,4348	0,2920	-0,3061	-4,6982	0,6502	-0,4797	
-2,0758	1,7785	1,9656	-2,4453	-0,2212	0,2268	

Tableau III.10. Poids et biais du meilleur modèle RQSP-RNA pour C_P (4-17-1).

Connexion des couches : (Entrée-Caché)					Connexion des couches : (Caché-Sortie)	
Poids				Biais	Poids	Biais
W_{j1}^1	W_{j2}^1	W_{j3}^1	W_{j4}^1	b_j^H	W_{1j}^H	b_1^0
3,3935	4,3896	2,8362	0,6826	0,8985	-2,4280	-1,0395
3,5247	-0,0244	-4,0617	2,2647	-0,7215	1,0818	
-2,8775	-2,1769	-1,4922	6,4051	1,7588	-2,3207	
1,5568	1,5568	0,5514	-1,5942	1,3930	4,6956	
2,4649	2,9694	1,2437	0,0359	1,1036	1,5030	
-1,8933	-1,5390	-0,4402	0,9514	-1,3181	-3,3759	
6,4768	-6,9262	1,0326	3,6713	-3,9303	4,6193	
1,7195	0,9143	-0,4027	-0,5820	-0,9602	-1,5051	

-10,0300	5,8272	-0,7078	1,0225	-0,0427	-1,5051
-0,2214	0,7859	0,2262	-0,9202	1,6758	-0,6824
-0,9314	-0,4691	0,0985	-0,3209	-0,4306	0,9406
-6,0126	-5,6908	-0,8297	-0,9271	6,8248	4,8790
2,5957	3,6907	0,9948	0,2684	1,0396	2,4814
-0,0692	3,4181	1,4663	2,7959	-5,8782	6,0526
3,1682	2,0881	0,9617	-0,7187	1,4332	3,4349
10,3098	0,8428	2,2919	-1,1394	-5,0273	6,2328
-1,9860	-2,4623	-0,3047	-0,4212	-2,6434	-0,1618

III.3.4. Estimation de la performance des résultats d'estimation issus des modèles RNA développés

III.3.4.1. Comparaison graphique entre les valeurs expérimentales et calculées à partir des modèles RNA

Afin d'estimer les trois paramètres liés aux dessalement de l'eau de mer : TC_P , Q_P et C_P , nous utilisons les modèles développés, en introduisant les valeurs des entrées E_i qui sont les valeurs des paramètres pertinents choisis pour chaque paramètre de sortie, plus les valeurs des poids (w_{ij}^I , w_{1j}^H) et les biais (b_j^H , b_1^O) de connexions correspondantes à chaque modèle.

Les comparaisons entre les valeurs expérimentales et calculées obtenues par les modèles de RNA développés sont illustrées sur les figures : **figure III.10** pour le modèle de TC_P , **figure III.11** pour le modèle de Q_P , et sur la **figure III.12** pour le modèle de C_P . Pour l'ensemble de la base des données entier.

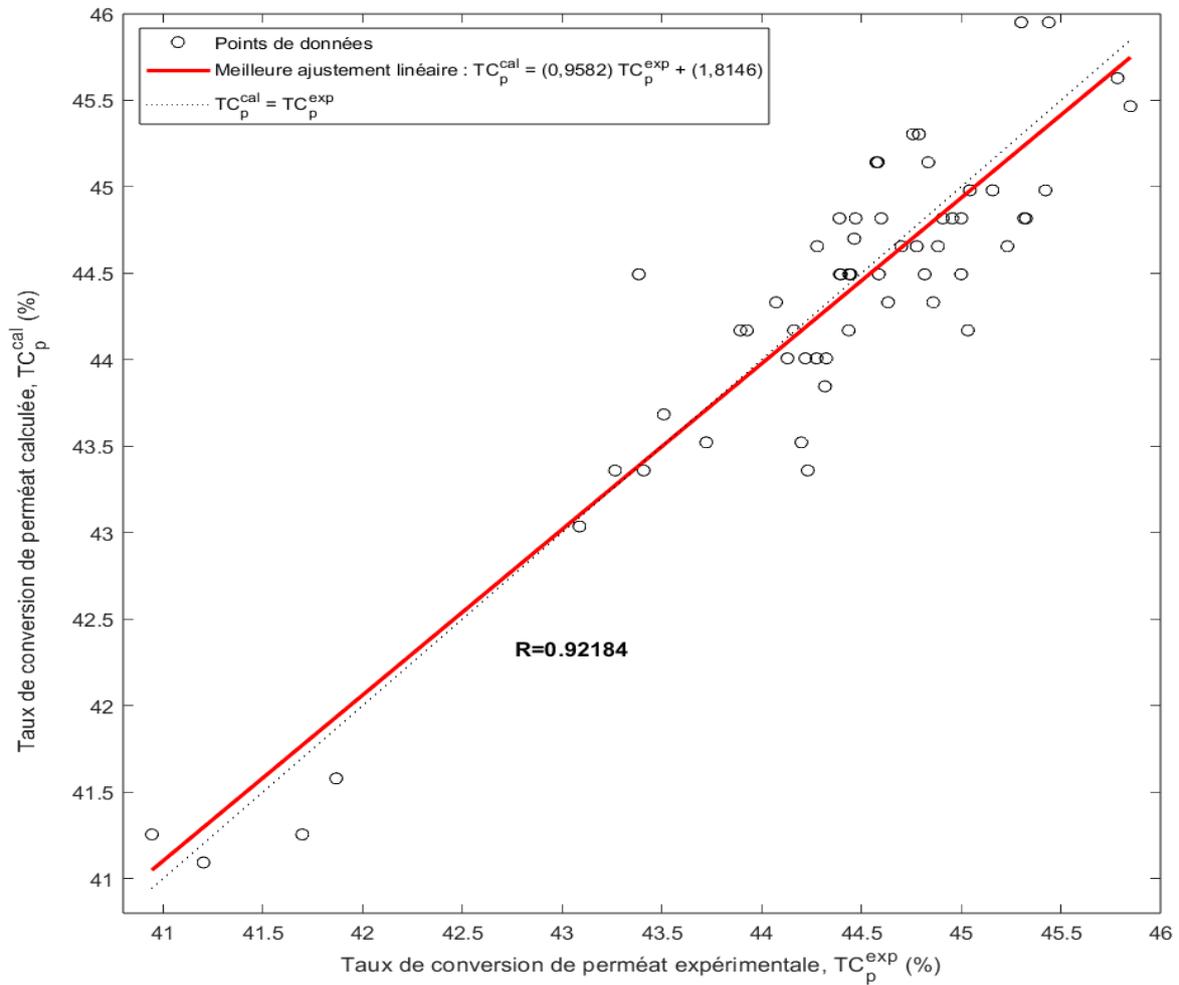


Figure III.10. Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de le taux de conversion de perméat TC_p pour la base des données entier.

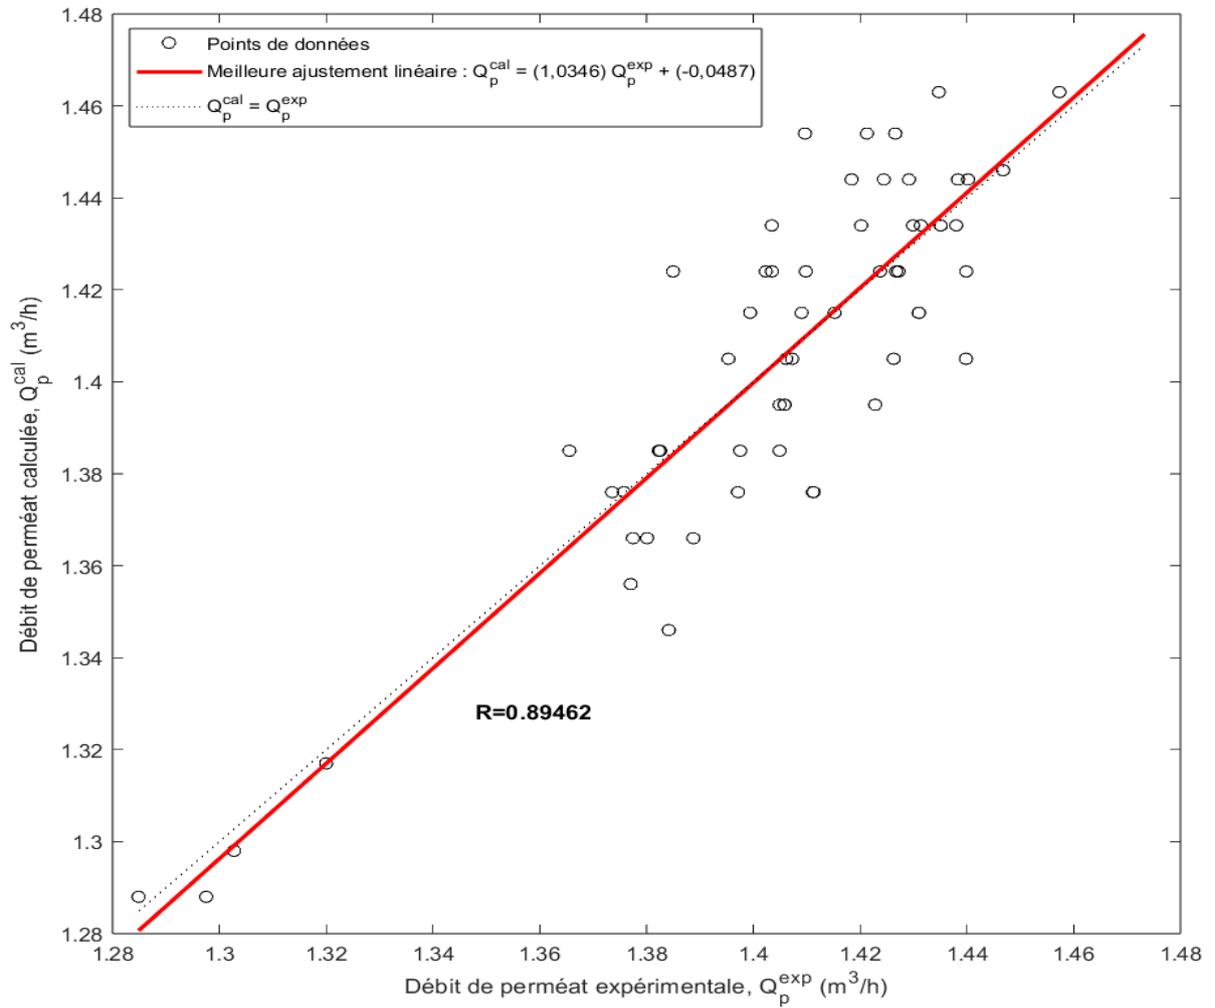


Figure III.11. Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de le débit de perméat Q_p pour la base des données entier.

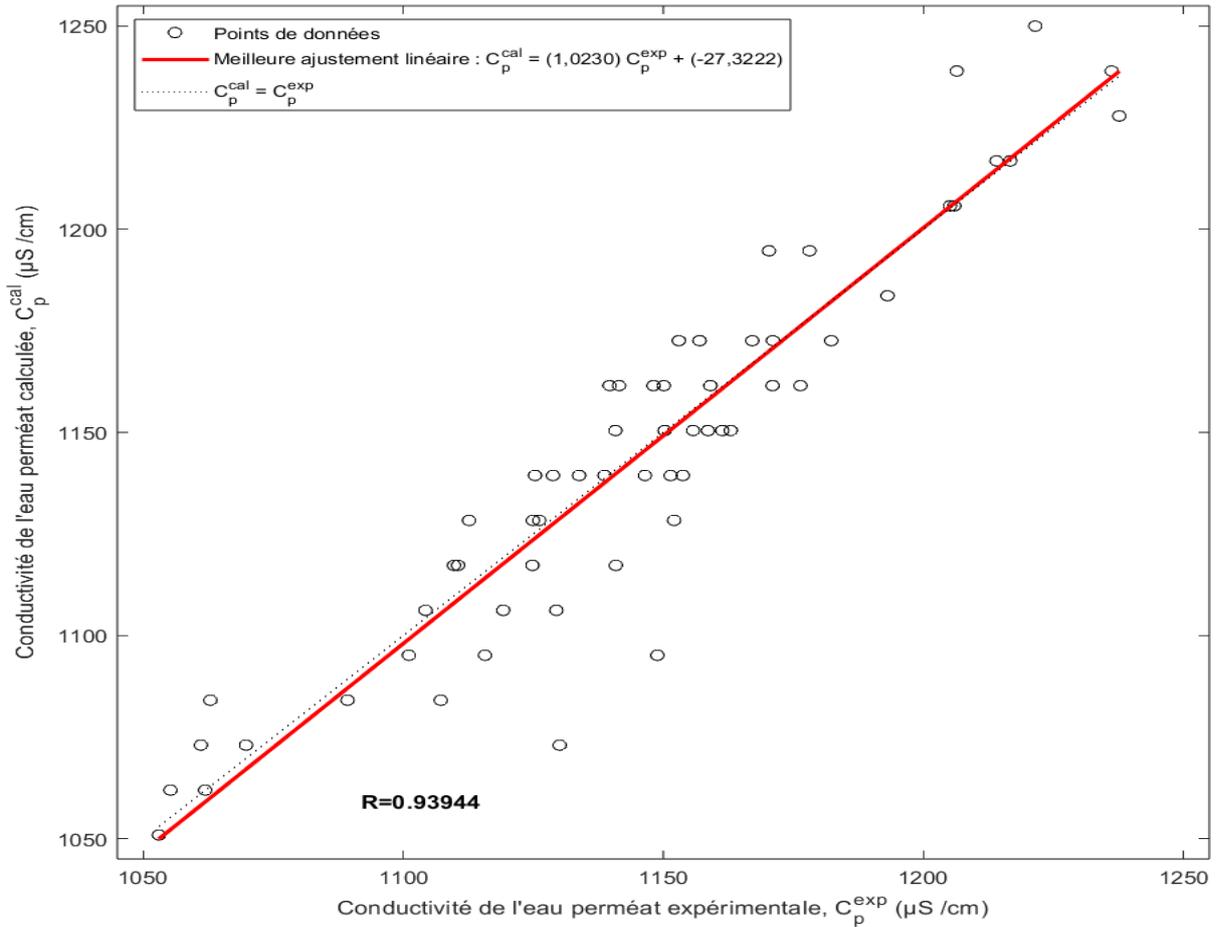


Figure III.12. Comparaison entre les valeurs expérimentales et calculées par le modèle RNA de la conductivité de l'eau perméat C_p pour la base des données entier.

Une concentration étroite de points de données autour de la ligne de pente unitaire (indiquée par la ligne en pointillé) révèle que les modèles peuvent prédire les trois valeurs paramètres avec une grande précision. Il a été confirmé qu'ils donnent des résultats satisfaisants, en accord de précision avec les valeurs vectorielles de corrélation proches de l'idéal (i.e. $\alpha = 1$ (pente), $\beta = 0$ (ordonnée à l'origine), $R = 1$), dans les graphiques appropriés des TC_P , QP et CP , pour l'ensemble de base des données entier (voir les équations de régression en haut de chaque figure). Sur cette base les modèles donnent de bons résultats avec des valeurs de R^2 élevées (voir également le **tableau III.11**).

III.3.5. Calculs des paramètres de performance et analyse statistique des modèles de type RNA obtenus

Les performances des meilleurs modèles de RNA sont résumées dans le tableau (III.11), en termes de la racine d'erreur quadratique moyenne (REQM), l'erreur standard de prédiction (ESP), l'erreur relative moyenne (ERM), et l'erreur relative absolue moyenne (ERAM), correspondant à chaque modèle dans l'ensemble de base des données : entier, d'apprentissage et du test. En plus des valeurs de R et R^2 , les valeurs de la pente (α), de l'interception (β) et le nombre de points de données (N) dans chaque phase. Les définitions mathématiques des types d'erreurs précédentes, du coefficient de régression (R), et du coefficient de détermination (R^2), sont respectivement, données par les Eqs (I III.1–I III.6) dans la partie III.2.2.4 du chapitre précédent (Matériels et méthodes).

Tableau III.11. Paramètres statistiques des meilleurs modèles de RNA pour les trois propriétés.

Paramètres Statistiques	R (-)	R ² (-)	REQM	ESP (%)	ERM (%)	ERAM (%)	α (-)	β (-)	N (-)
Phase d'apprentissage									
TC_P (%)	0,9333	0,8711	<u>0,3778</u>	0,8522	0,6939	0,6936	0,9514	2,1374	54
Q_P (m³/h)	0,8945	0,8001	<u>0,0187</u>	1,3298	1,0000	0,9995	1,0145	-0,0200	54
C_P (μS/cm)	0,9451	0,8932	<u>14,6871</u>	1,2800	0,9359	0,9385	1,0047	-5,0162	48
Phase de test									
TC_P (%)	0,9356	0,8754	<u>0,5254</u>	1,1917	1,0095	1,0184	4,1344	-139,1	6
Q_P (m³/h)	0,9451	0,8933	<u>0,0195</u>	1,1656	1,1221	1,1242	1,6140	-0,8602	6
C_P (μS/cm)	0,9182	0,8431	<u>23,1316</u>	2,0653	1,6634	1,6873	1,0350	- 45,6881	12
Phase entière (apprentissage + test)									
TC_P (%)	0,9218	0,8498	<u>0,3951</u>	0,8916	0,7255	0,7261	0,9582	1,8146	60
Q_P (m³/h)	0,8946	0,8003	<u>0,0185</u>	1,3146	1,0122	1,0120	1,0346	-0,0487	60
C_P (μS/cm)	0,9394	0,8825	<u>16,7207</u>	1,4642	1,0814	1,0883	1,0230	-27,322	60

Selon les résultats de différents coefficients statistiques et types d'erreur présentés dans le tableau (III.11.), les modèles développés étaient très intéressants, comme le montrent les

valeurs de R^2 supérieures à **0,8003** dans les trois modèles de : TC_P , Q_P et C_P ; pour la phase de base des données entière, d'apprentissage et de test.

Les valeurs de REQM calculées ont aussi confirmé que nos modèles sont très précis car ils ont des valeurs compris entre 0,3951–0,5254 % pour le paramètre TC_P , entre 0,0185–0,0195 **m3/h** pour le paramètre Q_P , et entre 16 ,7207–23,1316 **µS/cm** pour le paramètre C_P , ceci est pour les quatre phases des sous-ensembles possibles.

L'erreur standard de prédiction (ESP) est en fait de même type que celle de la REQM mais exprimée en pourcentage (%), ce qui donne une vision plus claire pour mieux juger les modèles. Les valeurs des ESP sont inférieures à 3% pour les trois modèles de TC_P , Q_P et C_P dans les trois sous-ensembles possibles. En fait qu'ils ont des valeurs de ESP comprise entre 0,8459–1,1917 % pour TC_P , entre 1,1656– 1,3146 % pour Q_P , et entre 1,3093–2,0653 % pour C_P .

Néanmoins, nous remarquons que toutes les valeurs d'erreurs calculées dans cette étude, très proche les uns aux autres pour le même paramètre et dans les trois sous-ensembles : d'apprentissage, de test et entière. Démontrant également l'équilibre entre le sous-apprentissage (sous-ajustement) et le sur-apprentissage (sur-ajustement) des modèles de RNA actuels, ce qui a confirmé encore la stabilité de nos modèles (**Bishop 1995 ; Pigram & MacDonald 2001 ; Hawkins 2004**).

III.3.6. Analyse de sensibilité des Paramètres dans chaque modèle de RNA par la méthode de poids

Comme je l'ai mentionné précédemment dans le paragraphe **III.2.2.5** (Matériels et méthodes), j'ai opté pour la méthode d'analyse de sensibilité au poids afin d'évaluer l'impact des paramètres d'entrée sur chaque modèle de RNA. Cette méthode permet de déterminer l'influence individuelle de chaque paramètre d'entrée sur la sortie de chaque modèle de RNA pour chaque paramètre spécifique. Les contributions des paramètres pertinents sur les modèles de RNA ont été évaluées et présentées de manière graphique sur les figures: Figure **III.13**, Figure **III.14** et la Figure **III.15**, respectivement pour les modèles de TC_P , Q_P et C_P .

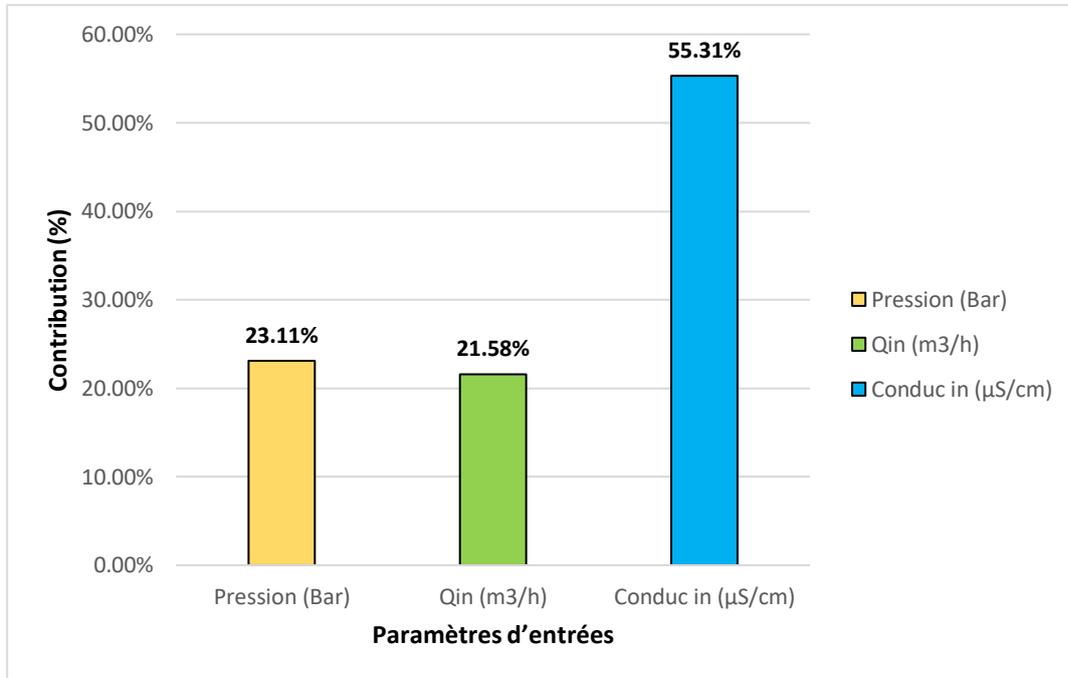


Figure III.13. Contributions relatives des Paramètres pertinents d'entrée pour le modèle de RNA de la le taux convention du perméat TC_P .

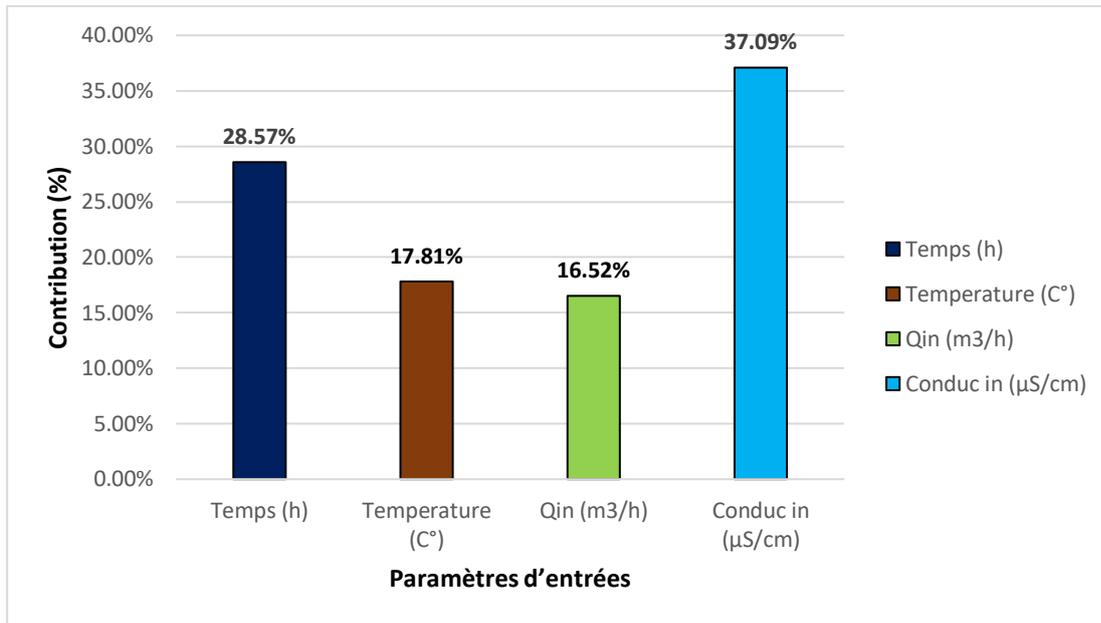


Figure III.14. Contributions relatives des Paramètres pertinents d'entrée pour le modèle de RNA de le débit du perméat Q_P .

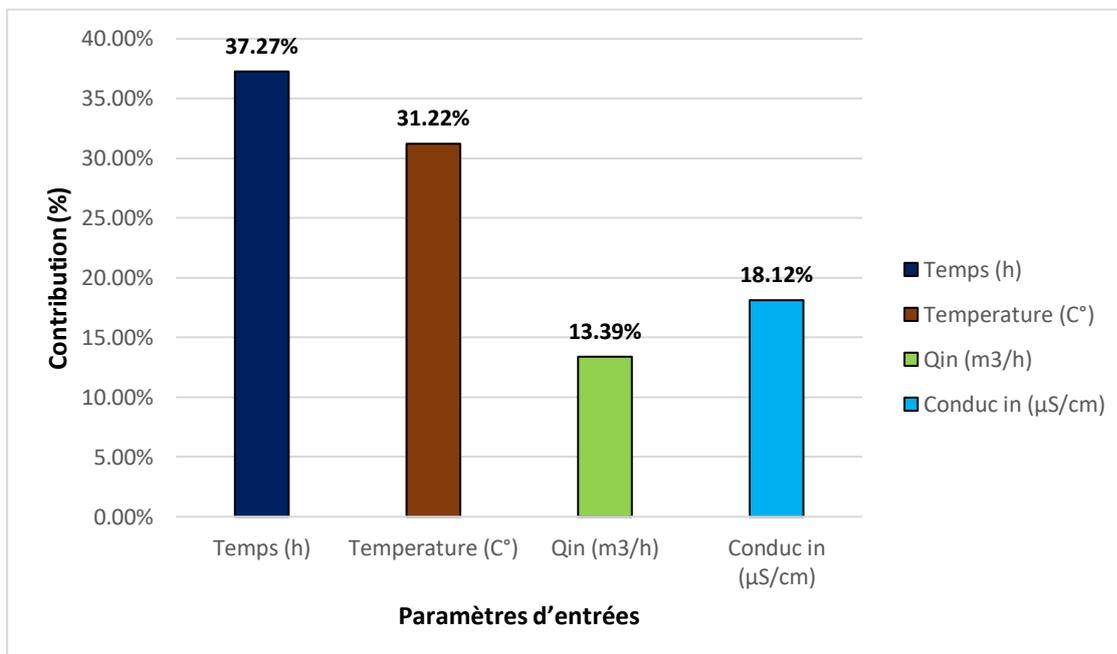


Figure III.15. Contributions relatives des Paramètres pertinents d'entrée pour le modèle de RNA de la conductivité du perméat C_P .

III.3.7. Interprétation et classification des contributions selon la (VCM)

D'après les résultats de l'analyse de sensibilité et les valeurs des contributions moyennes (VCM), calculées en divisant la contribution totale de chaque modèle (100%) par le nombre de paramètres dans le même modèle, les VCM calculées sont de 25% pour les modèles de Q_P et C_P , et de 33,33% pour le modèle de TC_P . À l'exception de quelques paramètres ayant des contributions faibles, la grande majorité des paramètres dans les trois modèles présentent une contribution moyenne ou forte.

Il est important de noter qu'il n'y a pas de grande différence entre les paramètres, en particulier ceux ayant des contributions moyennes ou fortes, par rapport aux (VCM) de chaque modèle. Cela indique que tous les paramètres sélectionnés étaient importants à divers degrés dans le développement des modèles de RNA.

III.4. Conclusion

Nous avons présenté dans ce chapitre l'ensemble des travaux de modélisation des trois paramètres critiques du dessalement de l'eau de mer : le taux de conversion du perméat (TC_P), le débit du perméat (Q_P), et la conductivité du perméat (C_P). Le chapitre est organisé en deux parties principales. Dans la première partie, nous avons expliqué l'ensemble des matériels et des méthodes utilisés lors du développement des modèles de type RNA en décrivant les différentes étapes. Nous avons cité tous les logiciels et les outils informatiques utilisés pour chaque étape du développement. Tous ces étapes ont été résumées dans un organigramme, ensuite nous avons expliqué en détail chaque méthode utilisée pour le développement des modèles, commençant par les étapes de prétraitement, ou bien précédemment par la procédure de collecte et traitement de la base de données.

Dans la seconde partie de ce chapitre, nous avons discuté l'ensemble des résultats obtenus par les modèles de type RNA développés afin de prédire les trois propriétés critiques importantes pour le dessalement de l'eau de mer : TC_P , Q_P et C_P . Nous avons discuté plusieurs résultats, tels que l'évaluation du nombre de paramètre au cours des étapes de prétraitement, les architectures et les résultats préliminaires des meilleurs modèles obtenus, l'estimation des erreurs et le calcul des coefficients statistiques pour chaque modèle comme le calcul des REQM et ESP, ainsi que l'analyse de la sensibilité des paramètre .

Les résultats de l'analyse de la performance des meilleurs modèles développés ont montré leur précision dans l'estimation des paramètres critiques du dessalement de l'eau de mer, confirmée par les valeurs élevées de leurs coefficients de détermination (R^2) et les faibles valeurs des deux erreurs calculées (REQM et ESP).

Conclusion générale

Conclusion générale

L'objectif principal de cette étude est la modélisation des processus de dessalement hybride combinant les techniques de Nanofiltration (NF), d'Osiose Inverse (OI), et de Distillation Multi-Étages (MSF). Cette recherche a été entreprise pour développer des modèles mathématiques de type Réseau de Neurones Artificiels (RNA) afin de prédire divers paramètres clés du processus de dessalement. Une base de données de 60 expériences, représentant des paramètres tels que le temps (t), la pression (P), la température (T), le débit d'entrée (Q_{in}), la conductivité de l'eau en entrée (C_{in}), le taux de conversion de perméat (TC_p), le débit de perméat (Q_p) et la conductivité de l'eau perméat (C_p), a été utilisée. Les données ont été prétraitées pour sélectionner les entrées pertinentes, et les corrélations entre les variables ont été calculées.

L'ensemble de données a été divisé au hasard en trois partitions : la première contient 70% pour la phase d'apprentissage et 30% pour la phase de test, la deuxième de la même façon avec 80% pour l'apprentissage et 20% pour le test, et finalement la troisième avec 90% pour l'apprentissage et 10% pour le test. L'algorithme BFGS a été appliqué pour entraîner les RNA. L'architecture des meilleurs modèles obtenus était : "03-08-01" pour le taux de conversion de perméat (TC_p), "04-10-01" pour le débit de perméat (Q_p), et "04-17-01" pour la conductivité de l'eau perméat (C_p). Les résultats étaient très encourageants, confirmés par les valeurs élevées du coefficient de détermination (R²) qui dépassent 0.90 pour les trois modèles, et les faibles valeurs de l'erreur quadratique moyenne (EQM). Les résultats de l'analyse de sensibilité ont clairement montré l'importance des paramètres d'entrée utilisés dans chaque modèle. Cette approche computationnelle peut être appliquée dans le domaine de l'ingénierie environnementale ou dans d'autres domaines connexes pour une détermination précise des paramètres des processus de dessalement en utilisant des paramètres liés aux structures chimiques et aux phénomènes physiques.

*Références
bibliographiques*

Références bibliographiques

- (**Tansakul,2009**) : procédés hybride à membranes pour les prétraitements d'eau de mer avant dessalement o/i thèse doctorat ; INSA Toulouse France 2009 .
- (**El- Ghonemy ,2012**) "waste energy in sea water reverse osmosis desalination plants part 2; case study " .renewable and sustainable energy reviews 16; 4016 - 4018 .
- (**Altaee et Sharif ,2011**) "Alternative design to dual stage NF seawater désalination using high rejection brackish water membranes "
- (**Bertels et Al ,2011**) " Optimization membrane performance at hybride NF plant " . IDA journal of desalination and water reuse
- (**Coupin -Montegut ,1996**) Chimie de l'eau de mer Institut oceanographique ,1996.
- (**Brown et Al ,1997**) Seawater : Its composition , properties and behaviour , The open University 2nd Edition ,1997 .
- (**Benner et Al ,1997**) Marine chemistry 57 ème Édition ,1997 .
- (**Al - Subaie et Al ,2007**) " Precise way to select a desalination technologie . Desalination ,206,29.35 .
- (**Al karaghoulis et Al ,2008**) " Solar and wind opportunities for water desalination plant using DEEP-3,2 Software ,journal 424,10-16
- (**Babou et Al ,2018**) " A review of clathrate hydrate based desalination to strengthen energy water Nexus .
- (**Ullah et Rasul ,2019**) " Recent development in solar thermal desalination technology , A review " energy .12; 119 .
- (**Madani et Al ,1994**) " Combined water purification and power of generating plant " us patent N05,34,592.
- (**Al karaghoulis et Al 2013**) energy consumption and water production cost of conventional and renewable energy powered desalination
- (**Balgin et Al ,2018**) Parametric Optimization of the MVC desalination plant with thermomechanical compressor " IOP conference series materials sciences and engineering 339.
- (**Chollom et Al ,2015**) " The applicability of Nanofiltration for the treatments and reuse of textile reactive Dye effluent "
- (**Zeman et Zydney ,2017**) " water SA : microfiltration et ultrafiltration : principales applications " CRC press ,618.
- (**Wu et Al ,2017**) " Gravity - driven microfiltration pre-treatment for reverse osmosis (RO) seawater desalination ; Desalination 418 ;1- 8 .

(**Akther et Al ,2015**) Recent advancements in osmosis desalination : a review "Chemical engineering journal 281 : 502 - 522 .

(**Berland et juery ,2002**) Les procédés membranaires pour traitement de l'eau " FNDAE Document , Technique FNDAE w14,paris .

(**Khawajia ,2008**) Advances in seawater desalination technologies; desalination 221 th édition ,2008.

(**Sin glande ,2006**) Procédés integre couplant l'eletrodialyse et le traitement biologique : Influence de la composition ionique et applications au traitement des influents salins , thèse de doctorat l'université Paul Sabatier

(**Bribiska,2005**) Colmatage des membranes par les minéraux et les protéines en cours d'electrodialyse conventionnelle collection des thèses électronique .

(**Hamani ,2013**) Étude de performance du pilote d'élèctrodialyse dans la déminéralisation des eaux saumâtres , Mémoire de fin d'études ; École nationale supérieure de l'hydrolique " Abraoui Abdallah '

(**Arzate A ,2008**) " Procédés de séparation membranaire et leur application dans l'industrie alimentaires " Thèse doctorat acer ,642 RVL - 0508 .

(**Qasin ,2019**) Memory retrieval modulates spatiale tuning of single neurones in the human entorhinal cortex

Bibliographie Chapitre II :

(**Hamadache,2014**) Modélisation en vue de prédiction ou de la corrélation de l'activité toxicologique à partir de la structure moléculaire ,thèse de doctorat

(**Khayrt M ,2011**) Artificielle neural net work modeling and réponse surface methodology of dessalination reserve osmosis journal of membrane science 368- 382-214

(**M parisien**) " Réseau de neurones " Gif - 21140 et Gif - 64326,2006 .

(**Intelligence Artificielle,2019**) <http://intelligence-artificielle-robotique-weebly.com>

(**Patterson ,1996**) Artificial neural networks Singapore: Prentice Hall,1996.

(**Mc culoch et pitts ,1943**) "A logical calculs of the ideas immanents in nervous activity" bull match Biphys 5:115 .

(**Bioshop ,1995**) neural networks for pattern recognition,oxford : université presse ,UK ,1995

(**Benrabeh et Al 2015**) Performance control of gas turbine ,turbomachinery international journal pp10 - 14 .

(**Rivales et Al 1995**) Modélisation , classification et commande par réseaux de neurones : principes fondamentaux méthodologie de conception illustration industriel , techniques et documentations .Lavorsier.paris

(**Al Shyji - KA ,2002**) Predictive modeling of large scale commercial water desalination plants data based neural network and model - based process simulation ; *Industrial and Engineering Chemistry research* 41;6460.6474.

(**Hagan et Al ,1996**) *Neural network design* PWS published company Boston ,USA .

(**Mac Donald,2001; Haw knis,2004**) The problem of overfitting *Journal of Chemical information and computer sciences* ,44(1),1-12

(**Stat Soft ,2007**) *statistica* (data analysis software system) vs 8.0 stat Soft ,Inc ,Tulsa,Ok

(**Suzuki ,2011**) *Artificial neural Network methodological Advances and biomedical applications*
BoD - Books on Demand

(**Beale et Al ,2012**) *Neural network toolbox user's guides in R 2012 a* , The math works ,Inc ,3 apple Hill Drive Natick ,Ma 01760.2098 ,www.math works.com

(**Gurney ;K,1997**) *An introduction to Neural Networks* ,Houtledge ,ISBN I - 85728 - 673 - I London .

(**Krose Smagt ,1997**) *An introduction to Neural Networks* the university of Amsterdam Netherland.

Bibliographie Chapitre 3:

(**Hamed,2009**) Performance Analysis of a trihybrid NF/RO/MSF. Desalination plant ; *Desalination and water treatment* 1(1-3) ; 215_222.

(**Silva et Al ,2000**) Hybrid feed - forward neural network model for the cephalosporin C production process

(**Hagan et Al 1996**) "*Neural network design* " PWS published company Boston .USA.

(**Hamadache et Al ,2016a**) A quantitative Structure activity relationship for acute oral toxicity of pesticides on rats : validation , domain of application and prediction of Hazards materials,303 ,28-40 .

(**Hamadache et Al 2016b**) Artificial neural network - based equation to predict the toxicity of herbicides on rats *Chemometrics and intelligent laboratory systems* 154,7-15 .

(**Malinav et Shan ,1996**) "*Software products for modelling and simulation in materials science*" *Comput mater science* 28:179 - 198 .

(**Tambe et Al ,1996**) "*Elements of artificial neural networks with selected Application in Chemical engineering and Chemical and biological science simulation* .

(**Ge et Al ,1996**) Prediction of corn Price fluctuation based on multiple linear regression analysis model under Big data "*Neural computing* ,1 -13".

(**Lee et Park ,1999**) "*Neural network modelling for on - line estimation of nutrient dynamics in a sequentially - operated Batch reactor* " *Biotechnol* ;75:229-239.

(Si - Moussa ,2008) Prediction of high pressure vapor liquid equilibrium of six binary . Systems ,carbon dioxide with six esters , using an Artificial neural network model " Brasilia journal of Chemical engineering . 25(1): 183 - 199.

Annexes

Annexe A

Tableau A.1. La base de données des paramètres liés au dessalement d'eau de mer

Temps (h)	Pression (Bar)	Temperature C	Q _{in} (m ³ /h)	Conduc in (micS/cm)	Taux conv permi %	Q permi (m ³ /h)	Condu permi micrS/cm
25,20	23,58	25,85	7,82	60170,21	41,58	1,32	1117,26
48,29	24,04	25,99	8,01	61021,28	41,26	1,29	1128,32
71,39	23,58	25,79	7,97	61234,04	41,09	1,29	1117,26
94,59	23,45	26,32	7,93	60382,98	41,26	1,30	1139,38
121,79	23,45	25,79	7,89	60382,98	44,49	1,39	1084,07
144,88	23,45	23,97	7,63	61553,19	43,36	1,35	1073,01
167,98	23,32	24,10	7,67	61765,96	43,36	1,37	1106,20
180,58	23,38	25,72	7,76	61766,00	43,52	1,38	1117,26
191,08	23,45	27,06	7,80	61569,57	43,68	1,38	1139,38
216,27	24,04	27,53	7,80	61234,04	44,01	1,39	1139,38
241,47	23,98	27,47	7,84	61127,66	44,82	1,42	1139,38
264,57	23,98	27,27	7,80	60702,13	44,98	1,46	1095,13
287,66	23,98	26,93	7,67	60808,51	45,95	1,42	1106,20
310,76	24,04	23,58	7,80	61765,96	44,17	1,39	1172,57
335,96	24,51	24,04	7,59	61872,34	43,04	1,36	1095,13
361,16	23,97	23,51	7,76	61021,28	44,82	1,41	1084,07
384,25	24,51	24,04	7,76	60808,51	44,82	1,40	1061,95
407,35	24,04	23,58	7,63	60702,13	44,98	1,42	1039,82
432,55	24,44	23,98	7,71	60489,36	44,66	1,42	1050,89
455,64	23,90	23,45	7,67	60489,36	44,66	1,39	1061,95
478,74	24,04	23,58	7,71	60382,98	45,30	1,43	1084,07
503,94	23,97	23,51	7,76	60382,98	44,82	1,42	1128,32
527,03	23,97	23,51	7,76	60276,60	44,17	1,37	1150,44
539,63	26,66	26,15	7,76	60276,60	44,33	1,38	1139,38
552,23	29,48	28,92	7,76	60382,98	44,49	1,38	1150,44
575,33	30,49	29,91	7,80	61127,66	44,49	1,39	1205,75
600,53	29,96	29,39	7,71	60382,98	44,01	1,37	1139,38
623,62	30,49	29,91	7,80	60276,60	45,30	1,44	1250,00
648,82	30,02	29,45	7,80	59957,45	44,82	1,42	1238,94
671,92	29,48	28,92	7,67	60063,83	45,30	1,42	1216,81
697,11	30,02	29,45	7,59	60063,83	44,98	1,40	1172,57
720,21	30,49	29,91	7,67	60063,83	44,49	1,38	1205,75
745,41	30,43	29,85	7,71	59851,06	45,47	1,42	1194,69
768,50	30,43	29,85	7,76	59851,06	45,63	1,43	1095,13
791,60	30,49	29,91	7,71	60063,83	45,14	1,41	1194,69
814,70	31,50	30,90	7,63	60063,83	45,95	1,48	1216,81
839,90	27,00	26,48	7,80	60276,60	44,66	1,44	1227,88

Référence Bibliographique

854,59	28,34	27,80	7,71	60276,60	44,70	1,42	1183,63
865,09	29,28	28,73	7,67	60276,60	44,33	1,41	1161,50
886,09	29,42	28,86	7,80	60276,60	45,14	1,41	1106,20
911,29	29,48	28,92	7,80	60276,60	45,14	1,45	1073,01
936,48	30,02	29,45	7,76	60063,83	44,82	1,45	1161,50
946,98	31,84	31,23	7,80	60063,83	44,82	1,45	1139,38
959,58	30,02	29,45	7,84	60063,83	44,82	1,43	1128,32
984,78	30,02	29,45	7,59	60170,21	44,49	1,43	1117,26
1007,87	29,48	28,92	7,76	60170,21	44,66	1,44	1161,50
1030,97	29,96	29,39	7,71	60170,21	43,36	1,40	1128,32
1056,17	29,75	29,19	7,80	61234,03	43,52	1,40	1161,50
1081,36	29,96	29,39	7,71	60808,51	44,49	1,45	1073,01
1102,36	29,96	29,39	7,71	60382,98	44,01	1,43	1150,44
1127,56	29,55	28,99	7,76	60170,21	44,01	1,42	1172,57
1150,66	29,01	28,46	7,76	60170,21	44,01	1,42	1150,44
1173,75	29,01	28,46	7,63	60063,83	44,66	1,46	1150,44
1201,05	30,02	29,45	7,80	60170,21	44,17	1,44	1150,44
1224,15	29,96	29,39	7,63	60170,21	43,85	1,41	1161,50
1247,24	30,70	30,11	7,76	60170,21	44,49	1,44	1172,57
1270,34	31,03	30,44	7,76	60382,98	44,49	1,42	1161,50
1295,54	28,81	28,27	7,59	60276,60	44,17	1,42	1172,57
1318,64	29,82	29,25	7,80	60276,60	44,33	1,43	1161,50
1343,83	28,81	28,27	7,84	60382,98	44,17	1,43	1238,94