REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE YAHIA FARES DE MEDEA



Faculté de **T**echnologie

Département de **G**énie des **P**rocédés et **E**nvironnement

En vue de l'obtention du diplôme de MASTER en Génie des Procédés

Filière : Génie des Procédés
Spécialité : Génie des procédés des matériaux

Modélisation du vieillissement membranaire

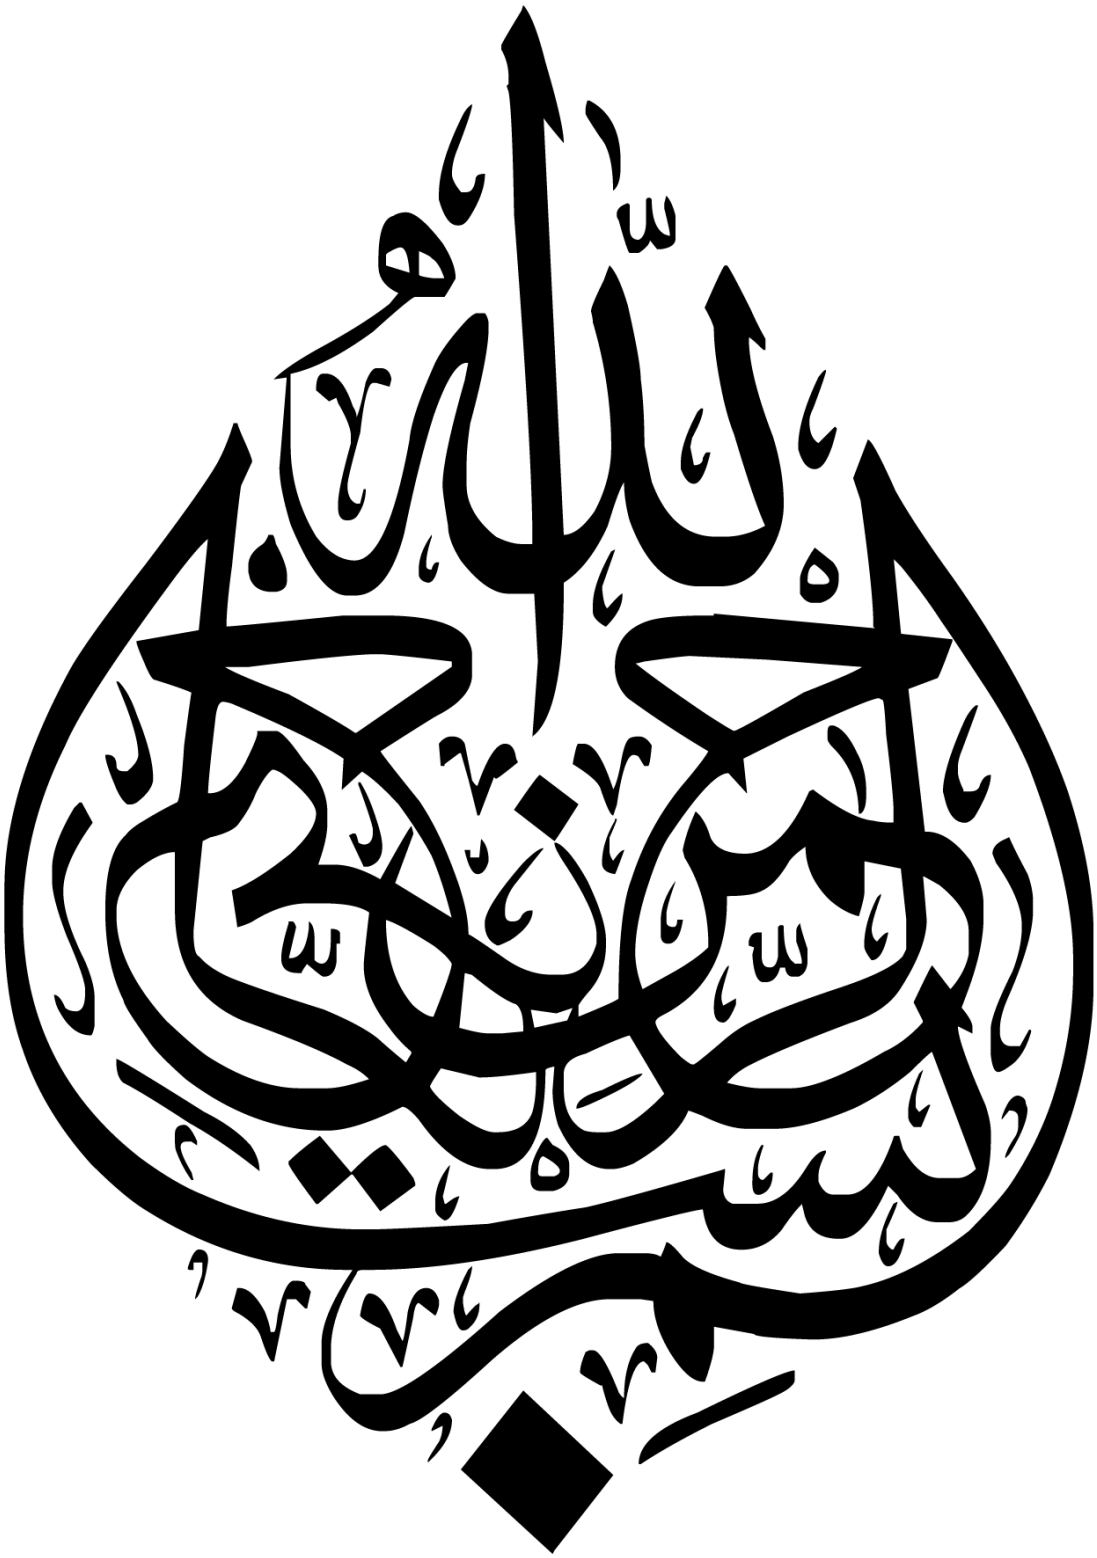
Présenté par :

- M^{me} GUESMIA Amel
- M^{elle} TERKMANE Meriem

Devant le jury composé de :

Nom & Prénom	Grade & Etablissement	En Qualité de
M^{me}. KHAOUANE Latifa	Professeur, UYFM UYFM	Présendente
M^{me}. CHABA MOUNA Siham	Maitre de conférence classe B, UYFM	Examinatrice
Mr. IBRIR Abdellah	Docteur, UYFM	Examinateur
Mr. HANINI Salah	Professeur, UYFM	Co-promoteur
M^{elle}. AMMI Yamina	Maitre de conférences classe A, UYFM	Promotrice

Promotion 2022-2023



Remerciements et gratitude

Tout d'abord, je tiens à remercier ***ALLAH*** *tout puissant pour toutes les merveilles qu'il fait dans ma vie et pour m'avoir donné le courage, la force et la patience d'achever ce modeste travail.*

Nous remerciements les plus sincères vont à Madame ***Yamina AMMI****, Maître de conférences classe A à l'UYFM pour leurs conseils précieux et leur suivi qu'elle nous a prodigué durant tout notre travail.*

Nous adressons également mes plus grands remerciements au Monsieur ***Salah HANINI****, Professeur à l'UYFM, il nous a guidé dans notre travail et nous a aidé à trouver des solutions pour avancer.*

Mes vifs remerciements vont aux membres de juger mon présent notre travail. Madame ***Latifa KAHOUANE****, Professeur à l'UYFM, Madame* ***Siham CHABA MOUNA****, Maître de conférences classe B à l'UYFM, Maître de conférences classe B à l'UYFM et Monsieur* ***Abdellah IBRIR,*** *docteur à l'UYFM.*

Enfin toute personne qui a participé de près ou de loin de l'accomplissement de ce mémoire

Soit sincèrement remerciée les enseignants qui ont participé à nos formations soient sincèrement remerciés

Dédicaces

À mes chères parents ma mère et mon père

Pour leur patience, leur amour, leur soutien et leurs encouragements.

À mon frère Younes.

À mes sœurs Sakina et Hadjer

À mon mari et sa famille.

À mon binôme Terkmane Meriem à la réalisation de ce modeste travail.

À mes chères amies (Sabah, Touba, Noujoud, Sara et Ikram)

Amel



Dédicace

À mes chères parents ma mère et mon père

Pour leur patience, leur amour, leur soutien et leurs encouragements.

À mon frère Mohamed Amine.

À mes sœurs Imane et Amina.

À tous la famille Terkmane et Toubal.

À mon binôme Guesmia Amel à la réalisation de ce modeste travail.

À toute la promotion de Génie des procédés des matériaux promotion 2022/2023

À tous ceux qui m'ont soutenu de près ou de loin

Meriem



ملخص

نمذجة شيخوخة الغشاء

الهدف المحدد لهذا العمل هو تطوير النماذج العصبية (RN) لنمذجة شيخوخة الغشاء

تتميز النماذج العصبية (RN) Feedforward ببنية (ستة خلايا عصبية لـ RN1،RN2 وRN3) في طبقة الإدخال، وطبقة مخفية وخلايا عصبية واحدة في طبقة الإخراج). تم استخدام ثلاث قواعد بيانات (304 نقاط بيانات، 169 نقاط بيانات و166 نقاط بيانات) لإنشاء RN1 ،RN2 وRN3 على التوالي. تم استخدام 60٪ ، 20٪ و 20٪ من مجموعة البيانات للتدريب والتحقق من الصحة والاختبار على التوالي. بالنسبة للنماذج الواعدة للشبكات العصبية، تمت مقارنة قيم المحسوبة لمرحلة الاختبار بالقيم التجريبية، وتم العثور على ارتباطات جيدة (R = 0.9845 لـ RN1، R = 0.9968 لـ RN2 و R = 0.9920 لـ RN3). أظهر تحليل الحساسية بطريقة الوزن أن المتغيرات الأكثر صلة بنفاذية الماء والمذاب لغشاء قديم هي: وقت الترشيح، ودرجة الحموضة، وجرعة HOCL، والتركيز المولي لمحلول التغذية، الكتلة المولية للمذاب والضغط، والمتغيرات الأكثر صلة بالاستطالة عند كسر غشاء قديم هي: وقت الترشيح، والتركيز المولي، ودرجة الحموضة والكتلة المولية للمذاب.

الكلمات الرئيسية: النمذجة؛ الشبكات العصبية الاصطناعية؛ الشيخوخة؛ الغشاء.

Abstract

Modeling the membrane aging

The objective assigned to this work is to develop neural models (NN) to model membrane aging.

Feedforward neural (NNA) models are characterized by a structure (six neurons for NN1, NN2, and 4 neurons for NN3 in the input layer, one hidden layer, and one in the output layer). Tree databases (304 data points, 169 data points and 166 data points) were used to create RN1, RN2, and RN3 respectively. 60%, 20%, and 20% of the data set were used for training, validation, and testing respectively. For the most promising models of neural networks, the calculated values of the test phase were compared to the measured values, and good correlations were found (R = 0.9845 for NN1, R = 0.9968 for NN2, and R = 0.9920 for NN3). The sensitivity analysis by the weight method revealed that the most relevant variables on the permeability of water and solute of an old membrane are: the filtration time, pH, the dose of HOCL, the morality of feed solution, the molecular weight of solute, and the applied pressure and the most revealed variables on the elongation at rupture of an old membrane are: filtration time, molarity, pH, and Ms.

Keywords: Modeling; artificial neural networks; Aging; Membrane.

Résumé

Modélisation du vieillissement membranaire

L’objectif assigné à ce travail est d’élaborer des modèles neuronaux (RN) pour modéliser le vieillissement membranaire.

Les modèles neuronaux du type feedforward (RN) caractérisé par une structure (six neurones pour RN1, RN2 et quatre neurones pour RN3 dans la couche d'entrée, une couche cachée et un neurone dans la couche de sortie). Trois bases de données (304 points de données, 169 points de données et 166 points de données) ont été utilisées pour créer RN1, RN2 et RN3 respectivement. 60%, 20% et 20% de l'ensemble des données ont été utilisées respectivement pour l’apprentissage, la validation et le test. Pour les modèles les plus prometteurs de réseaux neuronaux, les valeurs calculées de la phase de test ont été comparées aux valeurs mesurées, de bonnes corrélations ont été trouvées (R = 0.9845 pour RN1, R = 0.9968 pour RN2 et R= 0.9920 pour RN3). L'analyse de sensibilité par la méthode de "poids" a révélé que les variables les plus pertinentes sur la perméabilité de l’eau et soluté d’une membrane vieille sont : le temps de filtration, le pH, la dose de HOCL, la molarité de solution d’alimentation, la masse molaire de soluté et la pression appliquée et les variables les plus pertinentes sur l’allongement à la rupture d’une membrane vieille sont : durée de filtration, molarité, pH et Ms.

Mots clés : Modélisation ; Réseau de neurones artificielle ; Vieillissement ; Membrane.

Abréviations i
Nomenclatures et symboles ii
Liste des tableaux iv
Liste des figures v

Introduction générale 01

Chapitre I. Vieillissement membranaire

I.1. Introduction 04
I.2. Généralités sur les membranes 04
I.2.1. Définition de la membrane 04
I.2.2. Classification des membranes 05
I.2.2.1. Classification d'après la morphologie 05
I.2.2.2. Classification d'après la nature chimique 06
I.2.2.3. Classification d'après la géométrie de préparation des membranes 07
I.2.2.4. Classification d'après le mécanisme de séparation 08
I.2.3. Modules membranaires 09
I.2.3.1. Modules plans 09
I.2.3.2. Modules spiralés 10
I.2.3.3. Modules tubulaires 11
I.2.3.4. Modules à fibres creuses 12
I.2.4. Techniques de filtration membranaire 12
I.2.4.1. Microfiltration (MF) 12
I.2.4.2. Ultrafiltration (UF) 12
I.2.4.3. Nanofiltration (NF) 13
I.2.4.4. Osmose 13
I.2.4.5. Osmose Inverse (OI) 13
I.2.5. Caractérisations des membranes 14
I.2.5.1. Taux de conversion 14
I.2.5.2. Sélectivité 14
I.2.5.3. Pression osmotique 15
I.2.5.4. Transfert de solvant et de soluté 15
I.2.5.4.1. Flux de solvant 15
I.2.5.4.2. Flux de soluté 16
I.3. Vieillissements membranaires 16
I.4. Principes du vieillissement des polymères 17
I.4.1. Vieillissement physique 17
I.4.2. Vieillissement chimique 18
I.4.2.1. Vieillissement thermochimique 18
I.4.2.2. Vieillissement photochimique 18
I.4.2.3. Vieillissement hydrolytique 18
I.4.2.4. Vieillissement radiochimique 19
I.5. Vieillissement chimique de membranes par exposition à du chlore 20
I.6. Modification des propriétés de transfert de membranes lors de vieillissement chimique 21
I.7. Conclusion 22

Chapitre II. Réseaux de neurones artificiels

II.1. Introduction 23
II.2. Historique 23
II.3. Réseaux de neurones artificiels (RNA) 24
II.3.1. Neurone biologique 24
II.3.2. Neurone formel 24
II.3.3. Architecture d'un réseau de neurones 27
II.3.4. Apprentissage des réseaux de neurones 28
II.3.4.1. Apprentissage non supervisé 29
II.3.4.2. Apprentissage supervisé 29
II.3.4.3. Apprentissage forcé ou imposé 30
II.4. Réseaux de neurones les plus utilisés 30
II.4.1. Perceptron monocouche (perceptron simple) 31
II.4.2. Perceptron multicouche (en anglais Multi Layer Perceptron) 31
II.4.3. Réseaux à fonction radiale 32
II.4.4. Cartes auto-organisatrices de Kohonen (SOM) 32
II.4.5. Réseaux de Hop Field 32
II.4.6. Réseaux ART 33
II.5. Conception d'un modèle neuronal 33
II.5.1. Détermination des entrées/sorties du réseau de neurones 33
II.5.2. Construction de la base de données et choix des échantillons 34
II.5.3. Définition de la structure du réseau 34
II.5.3.1. Nombre de couches cachées 35
II.5.3.2. Nombre de neurones cachés 35
II.5.4. Apprentissage 35
II.5.5. Evaluation des performances du réseau de neurones 38
II.5.6. Limites 39
II.6. Conclusion 39

Chapitre III. Modélisation du vieillissement membranaire

III.1. Introduction 40
III.2. Collecte des données, prétraitement et analyse 40
III.3. Développement des modèles RN 46
III.4. Performance des modèles neuronaux 48
III.5. Expressions mathématiques des modèles neuronaux optimaux 55
III.6. Analyse de sensibilité par la méthode de poids 60

III.7. Diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimisé 62
III.8. Conclusion 65

Conclusion générale et perspectives 67
Références bibliographiques 69

Symbole	Signification
A	Perméabilité
ART	Adaptive Résonance Theory
As	Perméabilité de soluté
Aw	Perméabilité de l'eau
Ɛr	Allongement à la rupture
BD	Basse de données
BFGS	Broyden–Fletcher–Goldfarb–Shanno
C	Concentration molaire du soluté (mol. m^{-3})
DS	Déviation Standard
EAM	Erreur absolue moyenne
ESP	Erreur de standard de prédiction
FFNN	Feed Forward Neuronal Network
I	Nombre d'espèces d'ions constituant le soluté
IR	Importance Relative
MF	Microfiltration
Mw	Masse molaire de soluté d'alimentation
NF	Nanofiltration
OI	Osmose Inverse
PE	Polyéthylène
PES	Polyethersulfone
PMC	Perceptron Multi-Couches
PMMA	Poly méthacrylate de méthyle
POM	Poly oxyde méthylène
PP	Polypropylène
PS	Polysulfone
PV	Polychlorure de vinyle
RBF	Radial Basis Function Network
REQM	Racine de l'erreur quadratique moyenne
RN	Réseaux de Neurones
RNA	Réseaux de Neurones Artificiels
RFR	Réseaux à fonction de bases radiales
RNFF	Réseaux de Neurones Feedforward
UF	Ultrafiltration

Lecture	Désignation	Unité
As	Perméabilité de soluté	(m/s)
Aw	Perméabilité de l'eau	(L/h.m^2.bar)
Ɛr	Allongement à la rupture	(%)
$\mathbf{C_{SP}}$	Concentration d'un soluté dans le perméat	(kg/m^3)
$\mathbf{C_{SA}}$	Concentration d'un soluté dans l'alimentation	(kg/m^3)
C	Concentration de la solution	(mol. m^{-3})
$\mathbf{C_0}$	Concentrations des molécules dans la couche de n-octanol	(mol. m^{-3})
$\mathbf{C_w}$	Concentrations des molécules dans la couche de l'eau	(mol. m^{-3})
Dose de HOCl	Dose d'hydroxyle de chlore	(ppm.h)
Durée	Durée de la filtration membranaire	(Heure)
EAM	Erreur Absolue Moyenne	(-)
EQM	Erreur Quadratique Moyenne	(-)
ESP	Erreur Standard de Prédiction	(nm)
M	Molarité	(mol/l)
MW	Masse molaire	cm^3/mole
P	Pression	(bar)
Pm	Pression transmembranaire effective	(pa)
$\mathbf{Q_A}$	Débit volumique d'Alimentation	(g.mol^{-1})
$\mathbf{Q_P}$	Débit volumique de Permeat	(m^3/h)
R	Constant des gaz parfaits	(8.31 J.mol^{-1}.K^{-1})
REQM	Racine de l'Erreur Quadratique Moyenne	(m^3/h)
S	Surface	(m²)
T	Température	(K)

Lettres Grecques

Lecture	Désignation	Unité
Π	Pression osmotique	(Pa)
ΔΠ	Différence de pression osmotique de part et d'autre de la membrane	(Pa)
$\boldsymbol{\alpha}$	Pente de la droite du meilleur ajustement linéaire	(-)
$\boldsymbol{\beta}$	Ordonnée à l'origine de la droite du meilleur ajustement linéaire	(-)

Exposants

Lecture	Désignation
cal	Calculée
exp	Expérimentale
H	Cachée (Hidden)
I	Entrée (Input)
O	Sortie (Output)

Indices

Lecture	Désignation
I	Élément i d'un vecteur
i,exp	Élément i d'un vecteur de valeurs expérimentales
i,cal	Élément i d'un vecteur de valeurs calculées
Ij	Croisement de la ligne i avec la colonne j d'une matrice
j	Élément j d'un vecteur
max	Maximum
min	Minimum
$\bar{x}$	Moyenne

Chapitre II. Réseaux de neurones artificiels

Tableau II.1.	Fonctions de transfert usuelles, a=f(n)	26
Tableau II.2.	Résumé des caractéristiques des algorithmes d'apprentissage de rétropropagation implantés dans MATLAB®	37

Chapitre III. Modélisation du vieillissement membranaire

Tableau III.1.	Taille de la base de données et le nombre de composés organique utilisés dans ce travail.	40
Tableau III.2.	Matrice des coefficients de corrélation pour la première base de données (BD1).	42
Tableau III.3.	Matrice des coefficients de corrélation pour la deuxième base de données (BD2).	42
Tableau III.4.	Matrice des coefficients de corrélation pour la troisième base de données (BD3).	43
Tableau III.5.	Entrées et sortie utilisées pour le développement des modèles neuronaux (RNA1, RNA2, RNA3).	44
Tableau III.6.	Analyse statistique des données d'entrée et de sortie (BD1).	44
Tableau III.7.	Analyse statistique des données d'entrée et de sortie (BD2).	45
Tableau III.8.	Analyse statistique des données d'entrée et de sortie (BD3)	45
Tableau III.9.	Effet de nombre de neurones et des fonctions d'activation dans la couche cachée.	50
Tableau III.10.	Structure des modèles $RN_{optimaux}$	51
Tableau III.11.	Vecteurs de régression linéaire issue de l'équation linéaire : [équation linéaire : $y^{cal} = \alpha y^{exp} + \beta$, α(pente), β(ordonnée à l'origine), R(coefficient de corrélation).	55
Tableau III.12.	Poids et biais du RN1 optimal.	59
Tableau III.13.	Poids et biais du RN2 optimal.	59
Tableau III.14.	Poids et biais du RN3 optimal.	60

Chapitre I. Vieillissement membranaire

Figure I.1.	Membrane sélective.	05
Figure I.2.	Différentes structures membranaires.	05
Figure I.3.	Membrane multicouche.	06
Figure I.4.	Membrane organique plane et asymétrique.	07
Figure I.5.	Gamme de rétention de différentes particules par les procédés membranaires.	09
Figure I.6.	Module plan Ray-Flow.	10
Figure I.7.	Module spiralé d'osmose inverse.	11
Figure I.8.	Module tubulaire de marque Synderfiltration.	11
Figure I.9.	Module à fibres creuses de marque Synderfiltration.	12
Figure I.10.	Techniques de filtration membranaire.	14
Figure I.11.	Processus de coupure statistique des squelettes macromoléculaires.	19
Figure I.12.	Processus de réticulation dans un polymère initialement linéaire et dans un polymère initialement tridimensionnel.	19
Figure I.13.	Principaux types de réactions conservant le squelette macromoléculaire (a) modification des groupements latéraux, (b) élimination de groupements latéraux et formation de doubles liaisons et (c) cyclisation intramoléculaire.	20

Chapitre II. Réseaux de neurones artificiels

Figure II.1.	Neurone biologique.	24
Figure II.2.	Neurone formel.	25
Figure II.3.	Structure d'un réseau de neurones non boucle.	27
Figure II.4.	Structure d'un réseau de neurones bouclé (récurent).	28
Figure II.5.	Principe de l'apprentissage non supervisé.	29
Figure II.6.	Principe de l'apprentissage supervisé.	30
Figure II.7.	Réseaux de neurones les plus utilisés.	31

Chapitre III. Modélisation du vieillissement membranaire

Figure III.1.	Sorties expérimentales en fonction de la durée de filtration membranaire : (a) BD1, (b) BD2 et (c) BD3.	47
Figure III.2.	Organigramme de développement et l'optimisation de l'architecture d'un RN.	48

Figure III.3.	Comparaison entre les valeurs expérimentales et les valeurs calculées pour RN1 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.	52
Figure III.4.	Comparaison entre les valeurs expérimentales et les valeurs calculées pour RN2 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.	53
Figure III.5.	Comparaison entre les valeurs expérimentales et les valeurs calculées pour RN2 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.	54
Figure III.6.	Performances des modèles neuronaux optimaux (RN1, RN2 et RN3) pour la phase totale.	56
Figure III.7.	Représentation schématique des : (a) RN1,(b) RN2et RN3 optimisés.	58
Figure III.8.	Architecture finale des réseaux de neurones optimaux de type feedforward pour la prédiction de la perméabilité de l'eau, la perméabilité de soluté et l'allongement à rupture membranaire veille par membrane.	60
Figure III.9.	Présentation des pourcentages de l'importance relative (*IR*) de chaque variable d'entrée sur la perméabilité de l'eau et la perméabilité de soluté et l'allongement à rupture membranaire vielle :(a) RN1, (b) RN2 et (c) RN3.	63
Figure III.10.	Diagnostic des données potentiellement suspectes et domaine d'applicabilité du modèle neuronal optimal "RNA2" pour : (a) la phase test et (b) la phase de total.	66

Introduction générale

La fin du XX^{ème} siècle a été marquée par un développement très important des techniques de séparation par l'intermédiaire de membranes neutres ou fonctionnalisées, pouvant être minérales ou organiques. Ces techniques non énergivores sont actuellement au cœur de plusieurs procédés industriels de production ou de traitement des eaux et d'effluents, et de fractionnement de mélanges de natures différentes (agroalimentaire, réactionnels,…) : électrodialyse, électro-électrodialyse, électrodialyse à membrane bipolaire, osmose direct, osmose inverse, nanofiltration, ultrafiltration, microfiltration,…Cependant, il reste difficile d'estimer la durée de vie de ces matériaux qui peut être très variable d'une application à l'autre. Les membranes tendent à perdre de leurs propriétés physicochimiques et séparatives tout au long de leur utilisation. Il s'agit là du phénomène de vieillissement de ces membranes. Ce phénomène s'accompagne d'une diminution du rendement des opérations et de l'augmentation de leurs coûts : surconsommation d'énergie, et/ou remplacement plus fréquent des membranes. Ainsi, l'évaluation de la durée de vie d'une membrane à la sortie de sa chaîne de production, ou de son degré de vieillissement après une certaine durée d'utilisation, constitue un élément très important dans la sélection des matériaux, dans la maîtrise des coûts opérationnels (investissement et fonctionnement) et dans la réduction de volumes des polymères à recycler (Ghalloussi – Alloui 2012).

En exploitation, les performances de membranes de filtration, notamment leur capacité de production, peuvent être altérées principalement par la formation d'un colmatage, phénomène inhérent à la rétention de solutés, résultant de la formation d'un biolfilm, de dépôts de colloïdes ou de solutés inorganiques (tartre) ou de la combinaison de ces types de colmatage. Des nettoyages sous pression, par injection d'air ou de réactifs (acide, base ou oxydants) sont périodiquement réalisés afin de limiter la perte des performances de membranes. La fréquence et l'amplitude (concentration utilisée, pression appliquée) des nettoyages sont contrôlés ou ajustés en raison de l'instabilité de certains polymères, utilisés comme matériaux membranaires, aux réactifs et/ou de leur sensibilité à des sollicitations mécaniques. La dégradation des polymères en surface d'une membrane lors des nettoyages ou par exposition à certains composés présents dans l'eau à traiter (par abrasion) peut entrainer une perte brusque de la sélectivité de membranes (Axel 2011).

La compréhension du mécanisme de vieillissement des membranes en exploitation constitue une démarche visant à aider les utilisateurs de membranes à appréhender et anticiper les risques associés à l'exploitation. Elle peut également promouvoir, au même titre que le besoin de limiter le colmatage des membranes, le développement ou la modification de polymères pour le traitement de l'eau par procédé membranaire. La modélisation est une autre approche permettant de diminuer le nombre d'expériences à effectuer pour déterminer l'influence des paramètres optimaux, des

propriétés interfaciales et structurelles des polymères sur la sélectivité d'une membrane vieille. Si elle représente bien le procédé, les influences des paramètres optimaux pourront être évaluées sans aucune expérience et n'auront qu'à être validés sur le site.

La technique des réseaux de neurones artificiels (RNA) a reçu beaucoup d'attention en tant qu'approche computationnelle fournissant un moyen alternatif et complémentaire de modélisation et ce en raison de sa capacité à faire face à des problèmes complexes et mal définis dans de nombreux domaines scientifiques : domaine de la météorologie, modélisation des variables de rayonnement solaire, modélisation d'un procédé industriel de fermentation de la pleuromutiline, prévision de la toxicité aiguë des pesticides, prédiction du rejet des composés organiques ... etc. Les modèles réseaux de neurones connaissent un développement très prometteur qui a amélioré la performance des approches statistiques existantes (Maouz 2020).

Le principal avantage des réseaux de neurones, comparé aux modèles de connaissance classique, est leur capacité à modéliser ces procédés sans avoir une connaissance approfondie de la phénoménologie mise en jeu. Un autre avantage important des modèles neuronaux, comparé à d'autres approximateurs universels tels que les régressions linéaires ou polynomiales, est qu'ils sont des approximateurs non-linéaires parcimonieux, permettant une modélisation de procédés non-linéaires quel que soit le nombre de paramètres indépendants utilisés (Ammi 2016).

L'objectif de ce travail est l'application des réseaux de neurones artificiels de type feedforward pour modéliser la perméabilité de l'eau, la perméabilité de soluté et l'allongement à rupture lors des membranes vieilles.

Pour atteindre l'objectif assigné à ce mémoire, trois chapitres ont été développés.

- ✓ Le premier chapitre s'attache à faire les points sur les généralités des membranes d'osmose inverse et de nanofiltration, vieillissements membranaires, principes du vieillissement des polymères, vieillissement chimique de membranes par exposition à du chlore, modification des propriétés de transfert de membranes lors de vieillissement chimique.
- ✓ Le deuxième chapitre est dédié à la présentation des réseaux de neurones artificiels "RNA".
- ✓ Nous présentons dans le troisième chapitre la modélisation de vieillissement membranaire. Il comptera six parties : la première partie présente la collecte des données, prétraitement et analyse, la deuxième partie sera consacrée au développement des modèles neuronaux, nous discuterons les performances des modèles neuronaux dans la

troisième partie, les expressions mathématiques de modèle neuronal optimal seront abordées dans la quatrième partie, nous traiterons dans la cinquième partie l'analyse de sensibilité par la méthode de poids et dans la dernière partie nous discuterons le diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimise.

Les conclusions tirées de ce travail ainsi que les études qui peuvent être envisagées à l'avenir sont présentées à la fin de ce mémoire.

Chapitre I. Vieillissement Membranaire

I.1 Introduction

Les membranes de filtration sont constituées d'un polymère majoritaire et potentiellement d'additifs. Comme tout matériau polymère, les membranes peuvent interagir avec leur environnement (UV, température, milieu aqueux par exemple) et se dégrader plus ou moins rapidement. Le vieillissement peut être chimique ou physique et souvent les deux types de vieillissement cohabitent. Le vieillissement physique n'engendre pas de modification de la structure chimique mais est principalement lié aux contraintes mécaniques appliquées au matériau, ou encore aux phénomènes d'adsorption ou de diffusion de molécules. Lors du vieillissement chimique, la structure chimique évolue suite à une exposition à une température élevée, à un rayonnement ou à un agent chimique réactif par exemple. L'évolution de la structure chimique peut alors être la cause de modification des propriétés du matériau (Ravereau-Delattre 2015).

Ce chapitre s'attache à faire les points sur les généralités des membranes, vieillissements membranaires, principes du vieillissement des polymères, vieillissement chimique de membranes par exposition à du chlore, modification des propriétés de transfert de membranes lors de vieillissement chimique.

I.2 Généralités sur les membranes

I.2.1 Définition d'une membrane

La membrane est définie comme une barrière séparant deux compartiments et permettant le passage préférentiel d'au moins une espèce parmi les autres sous l'action d'une force de transfert chimique (concentration …) ou physique (pression). En général, 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. Le résultat d'une opération membranaire est la séparation du fluide à traiter en deux parties de concentrations différentes (Figure I.1) :

- le retentât qui contient les molécules ou particules retenues par la membrane ;
- le permet qui contient les molécules qui traversent la membrane (Benmerak et Zahraoui 2022).

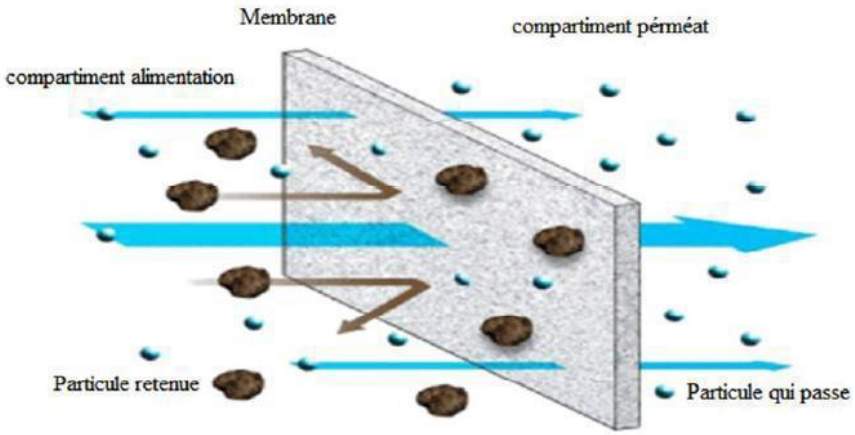


Figure I.1. Membrane sélective (Benmerak et Zahraoui 2022).

I.2.2 Classification des membranes

I.2.2.1 Classification d'après la morphologie

Les membranes peuvent être également classées en fonction de la structure des différents matériaux, on distingue :

- **Membranes à structure symétrique "isotrope"** : ce sont des membranes denses ou poreuses ayant la même structure (structure homogène) sur toute leur épaisseur (Ammi 2016).
- **Membranes à structure asymétrique "anisotrope" :** la structure de la membrane varie d'une couche à une autre (Figure I.2 "b"). Celles-ci présentent une structure hétérogène.

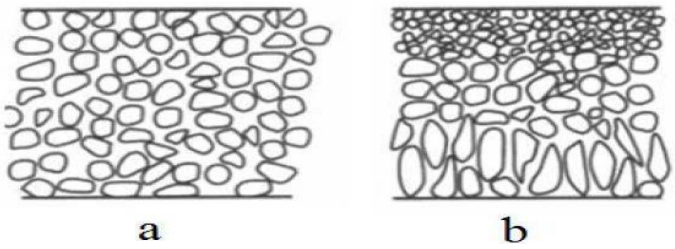


Figure I.2. Différentes structures membranaires (Chabane 2015).

Deux sous-types de membranes asymétriques peuvent été distingués :

- Membranes préparées à partir du même matériau.
- Membranes composites : ce sont des membranes constituées principalement de deux couches :

Peau : une couche de très faible épaisseur en contact direct avec l'eau à traiter. Cette couche donne à la membrane sa sélectivité.

Couche support : une couche plus épaisse, d'une perméabilité beaucoup plus grande, qui supporte la peau et confère à la membrane sa résistance mécanique.

- La plupart des membranes commerciales de MF, UF et de NF sont des membranes à structure asymétrique, car ce type de structure permet d'avoir des perméabilités plus élevées. Une membrane asymétrique est en général constituée d'une couche support macroporeuse (assurant une bonne résistance mécanique) et d'une couche active (régissant les propriétés de rétention entre lesquelles s'insèrent une ou plusieurs couches intermédiaires dont le rôle est de permettre le dépôt de la couche active et sa tenue en pression (Figure I.3) (Benmerak et Zahraoui 2022).

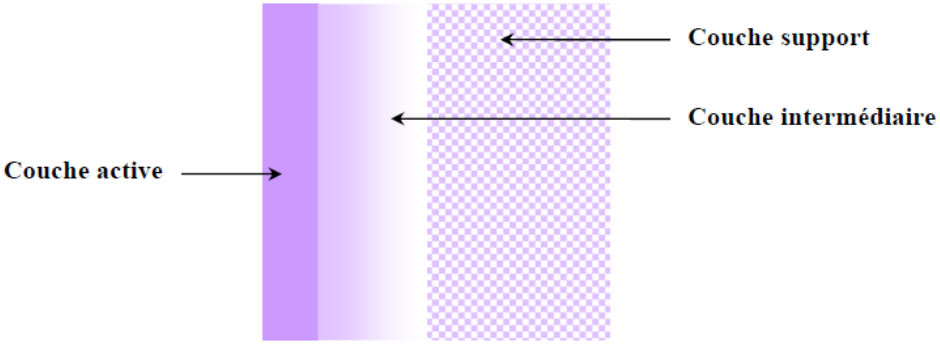


Figure I.3. Membrane multicouche (Ammi 2016).

I.2.2.2 Classification d'après la nature chimique

Les membranes sont fabriquées à partir des polymères organiques et de matières inorganiques. Les principaux polymères utilisés pour la fabrication des membranes sont (Benmerak et Zahraoui 2022).

A. Membrane organique

Elles sont fabriquées à base d'acétate de cellulose ou à partir de polymères de synthèse. Parmi les polymères les plus utilisés, on rencontre entre autres, les poly sulfones, les polyamides aromatiques, les polyamides, les poly éther sulfones, les polycarbonates, ainsi que des polymères fluorés possédant principalement une structure asymétrique. Le plus souvent un premier polymère présentant une structure macroporeuse est utilisé comme support (polyester, …) et un second polymère forme la couche active de la membrane (Figure I.4). La gamme de polymères disponibles permet d'avoir un éventail varié d'applications (on choisit un polymère selon ses propriétés pour répondre à un problème donné). Les membranes organiques sont les plus utilisées malgré leurs

résistances thermiques et chimiques relativement limitées car elles sont nettement moins chères que les membranes minérales.

Elles ont ainsi permis d'étendre la technologie de la filtration membranaire à différents secteurs industriels et par conséquent d'augmenter significativement le nombre des applications des procédés membranaires (Boudjnane 2018).

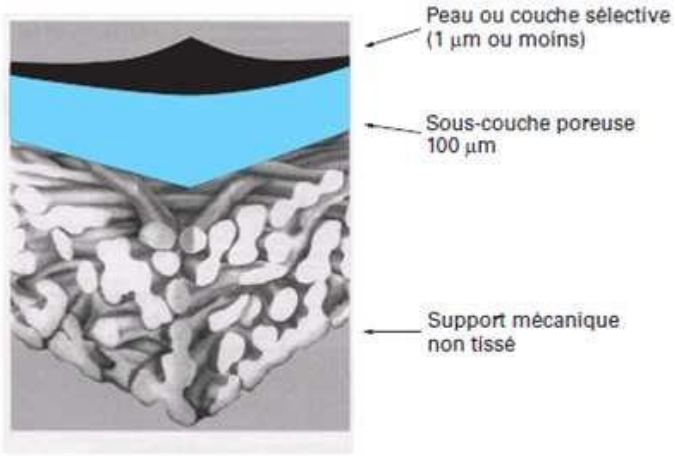


Figure I.4. Membrane organique plane et asymétrique (Boudjnane 2018).

Les membranes composites : Elles sont créées à partir des deux types précédents. Il s'agit de membranes minérales sur lesquelles on dépose des polymères où sur lesquelles on greffe d'autres composés tels que des silanes. Elles possèdent donc des propriétés qui sont un compromis entre les membranes organiques et inorganiques.

- **Dérivés de la cellulose :** ces polymères considérés généralement comme plus hydrophiles, peu coûteux et possédant une faible tendance à l'adsorption.
- **Poly sulfone (PS) et poly éther sulfone (PES) :** qui a une tendance à l'adsorption plus élevée que les membranes ci-dessus, mais avec une meilleure stabilité chimique, mécanique et thermique.

B. Membranes inorganiques

Sont fabriquées à base de céramique (oxydes d'aluminium de zirconium ou de titane). Ces membranes ont une stabilité chimique, mécanique et thermique supérieure que les membranes organiques (Ammi 2016).

I.2.2.2 Classification d'après la géométrie de préparation des membranes

Les membranes peuvent être classées en fonction de la forme sous laquelle elles sont fabriquées (Benmerak et Zahraoui 2022) :

- ✓ Membranes planes ;
- ✓ Membranes spirales ;
- ✓ Membranes cylindriques ;
- ✓ Membranes tubulaires (ayant le diamètre interne plus grand que 3 mm) ;
- ✓ Membranes creuses (ayant le diamètre plus petit que 3 mm).

I.2.2.3 Classification d'après le mécanisme de séparation

La classification est la plus répandue des membranes d'après le mécanisme de séparation est la suivante (Annane 2015) :

- **Membranes poreuses (MF, UF, NF)** où les effets de tamisage et de friction jouent des rôles importants, comme en NF, les forces de surface peuvent jouer un rôle important. Les pores peuvent être subdivisés en plusieurs catégories :
  - Macrospores-plus grands que 50 nm (MF).
  - Méso pores-2 à 50 nm (UF).
  - Micropores-plus petits que 2 nm (NF).

- **Membranes denses :** permutation de gaz, évaporation, osmose inverse (OI)) ; ces membranes peuvent être considérées comme des milieux denses où la diffusion des espèces à lieu dans les volumes libres situés entre les chaînes moléculaires du matériel de la membrane.

- **Membranes échangeuses des ions :** Ces membranes sont considérées comme un type spécial de membranes non poreuses, consistant dans des gels denses, ayant une charge positive (échangeuses des anions) ou négative (échangeuses des cations).

Il a noté que la communauté scientifique ne s'entende pas sur cette classification. Apte et Buckley 1996 considèrent que les membranes d'OI sont des membranes poreuses. La figure I.5 montre schématiquement la correspondance entre les opérations de filtration par membrane, la taille des pores et les composés retenus.

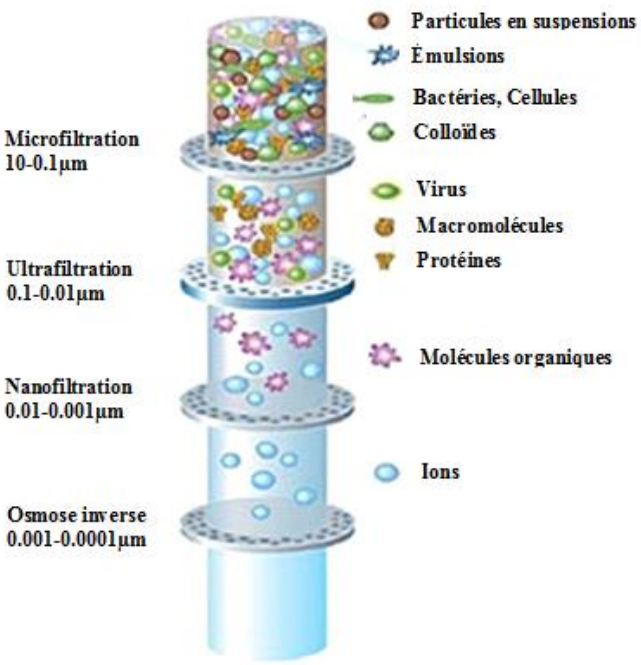


Figure I.5. Gamme de rétention de différentes particules par les procédés membranaires (Ammi 2016).

I.2.3 Modules membranaires

I.2.3.1 Modules plans

Cette configuration dérivée des filtres-presses est constituée d'un empilement de membranes sous forme des feuilles. Les membranes sont disposées parallèlement les unes aux autres et sont séparées par des grilles ou supports. Le module plan est un assemblage de type filtre-presse. Dans le cas du module Ray-Flow, la membrane est disposée à plat sur un support permettant l'écoulement et la collecte du perméat. L'écoulement de l'alimentation est tangentiel à la membrane et l'épaisseur de la veine liquide est assurée par l'épaisseur du joint qui rend étanche le montage (Figure I.6). Ce type de module est peu compact, mais facilement démontable pour le changement d'une ou plusieurs membranes (Marar et Mouas 2019).

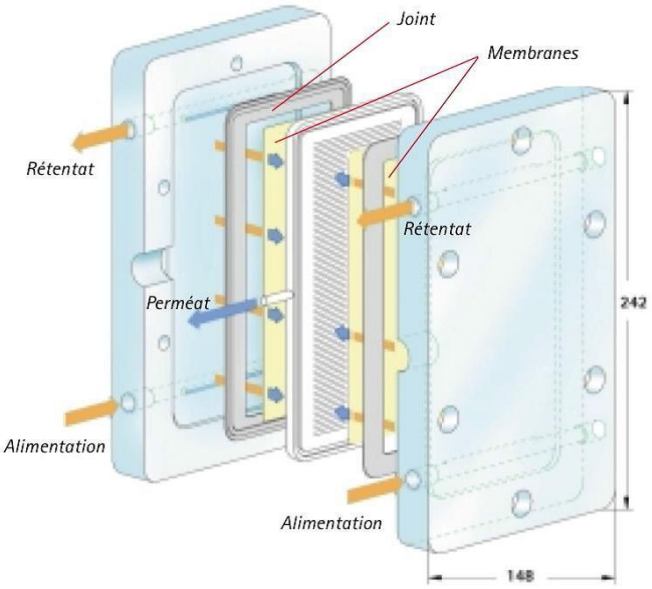


Figure I.6. Module plan Ray-Flow (Marar et Mouas 2019).

I.2.3.2 Modules spiralés

C'est un module particulier de membranes planes qui sont enroulées autour d'un axe creux collecteur de perméat. L'ensemble est introduit dans une enveloppe cylindrique dont les sections donnent accès à l'entrée de l'alimentation et à la sortie du retentât. Le module spiralé est composé d'un ensemble de membranes planes collées dos à dos, renfermant un espaceur de perméat et assurant l'écoulement du perméat dans le tube collecteur qui constitue l'axe central de la membrane. Du côté retentât, les membranes sont séparées par des espaceurs qui jouent le rôle de promoteur de turbulence et sont enroulés autour du tube collecteur (Figure I.7). Un grillage extérieur maintient l'ensemble enroulé. Le nombre des membranes collées dos à dos variées suivant les tailles des modules et des fabricants. Un module spiralé est beaucoup plus compact qu'un module plan (Ammi 2016).

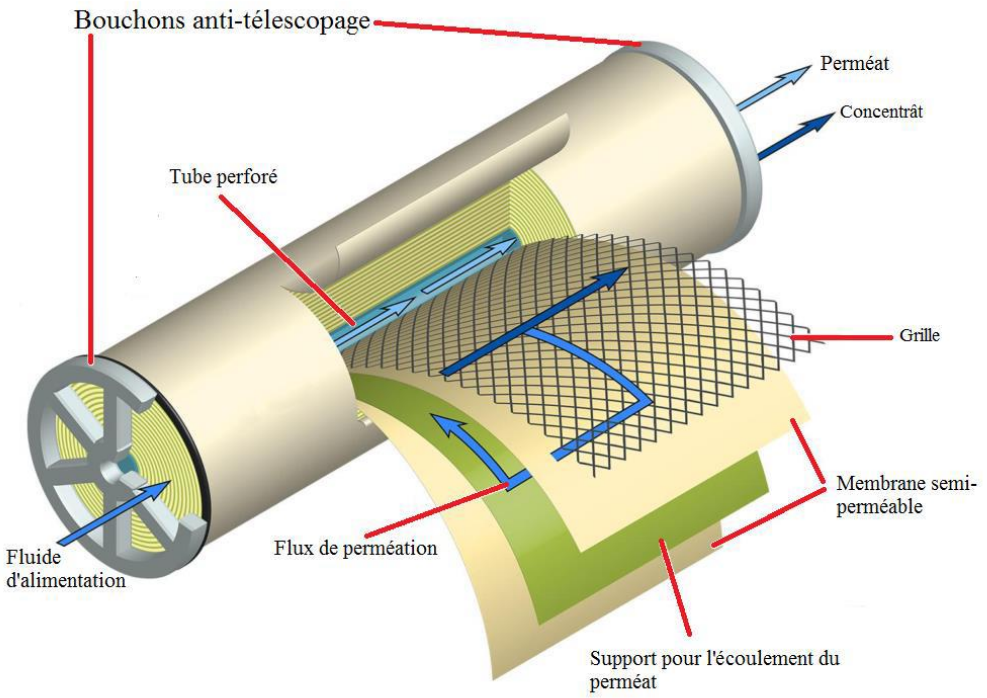


Figure I.7. Module spiralé d'osmose inverse (Marar et Mouas 2019).

I.2.3.3 Modules tubulaires

Les modules tubulaires sont constitués d'une ou plusieurs membranes inorganiques ou organiques de forme tubulaire, ayant des diamètres internes entre 4 et 25 mm. Plusieurs tubes individuels peuvent être placés dans un module (Figure I.8). Le module multicanaux est fait d'assemblage de tubes parallèles dans une même matrice qui représente la forme optimisée actuelle (Marar et Mouas 2019).

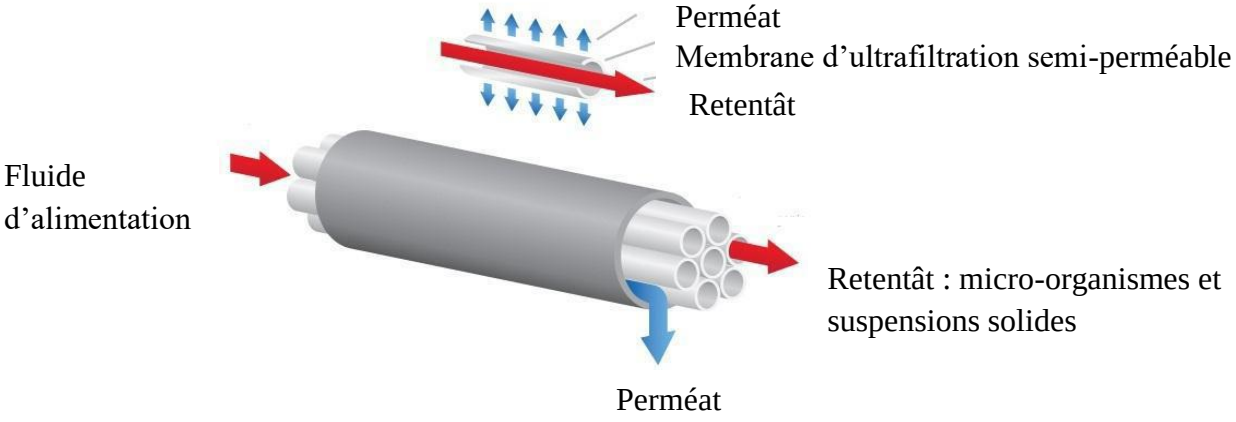


Figure I.8. Module tubulaire de marque Synderfiltration (Marar et Mouas 2019).

I.2.3.4 Modules à fibres creuses

Les modules à fibres creuses sont constitués de fibres membranaires disposées parallèlement dans un tube central perforé. La solution saline à l'intérieur du tube central se diffuse radialement autours des fibres (Ammi 2016) Figure I.9 est une représentation schématique d'un module à fibres creuses de marque Synderfiltration.

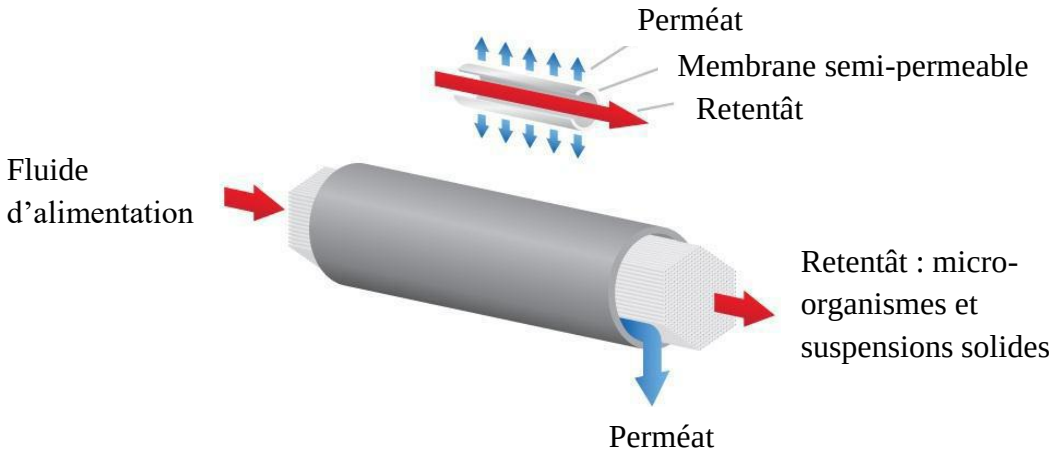


Figure I.9. Module à fibres creuses de marque Synderfiltration (Marar et Mouas 2019).

I.2.4 Techniques de filtration membranaire

On distingue quatre techniques de filtration selon le gradient de pression et la taille des pores, qui sont (Ammi 2016) :

I.2.4.1 Microfiltration (MF)

La Microfiltration pour laquelle la taille des pores est de l'ordre du micromètre se situant généralement entre 0,1 à 10 µm. C'est un procédé basse pression de 0,1 à 2 bars qui permet de séparer des composés à grand poids moléculaire (éléments en suspension ou éléments colloïdaux) des solides dissous. Ce procédé inclut la récupération de cellules issues de bouillons de fermentation, le fractionnement de protéines de lait, la clarification du sirop de maïs et la récupération de produits chimiques utilisés dans les phases de Nettoyage en Place (NEP) (Marar et Mouas 2019).

I.2.4.2 Ultrafiltration (UF)

L'Ultrafiltration se situe entre la microfiltration et la nanofiltration, avec une taille de pores variant de 1 à 100 nm (0.001 à 0.1 µm) est un procédé basse pression (1 à 5 bars) de séparation sélective utilisé pour purifier les composés de poids moléculaire moyen ou fort tels que les protéines

de lait ou végétales, les glucides et les enzymes. Les domaines d'application sont notamment la concentration des protéines sériques, la concentration et la déminéralisation des gélatines et la clarification des jus de fruit (Ammi 2016).

I.2.4.3 Nanofiltration (NF)

La Nanofiltration ou la taille des pores est de l'ordre de nanomètre (0,001 µm) est un procédé de filtration unique dont le domaine d'application se situe entre l'Ultrafiltration et l'Osmose Inverse sous une pression qui variée de 5 à 20 bars. Elle est conçue pour obtenir une séparation très spécifique des composés à faible poids moléculaire, tels que les sucres, des minéraux dissous et des sels. Ce procédé inclut la déminéralisation des produits laitiers, la récupération des protéines hydrolysées, la concentration des sucres ainsi que la purification des colorants solubles et des pigments (Ammi 2016).

I.2.4.4 Osmose

L'osmose est un phénomène de diffusion des molécules de solvant à travers une membrane semi-perméable qui sépare deux solutions dont les concentrations en produits dissous sont différentes. La différence de concentration provoque une différence de pression osmotique qui engendre un déplacement du solvant à travers la membrane. Le solvant passe de la solution la moins concentrée vers la solution la plus concentrée pour équilibrer les concentrations. Cette différence de concentration joue le rôle de force motrice de transport (Campbell et Jane 2007).

I.2.4.5 Osmose Inverse (OI)

L'Osmose Inverse est un procédé haute pression entre 20 et 80 bars, énergétiquement performant. Les membranes d'osmose Inverse ont des pores plus fins entre 0,001 et 0,0001µm, utilisé pour le traitement des eaux usées. Ce procédé est couramment utilisé aussi pour la préconcentration des produits laitiers ou alimentaires avant l'évaporation, le traitement des condensats des évaporateurs, la purification des eaux saumâtres et le dessalement de l'eau de mer (Marar et Mouas 2019).

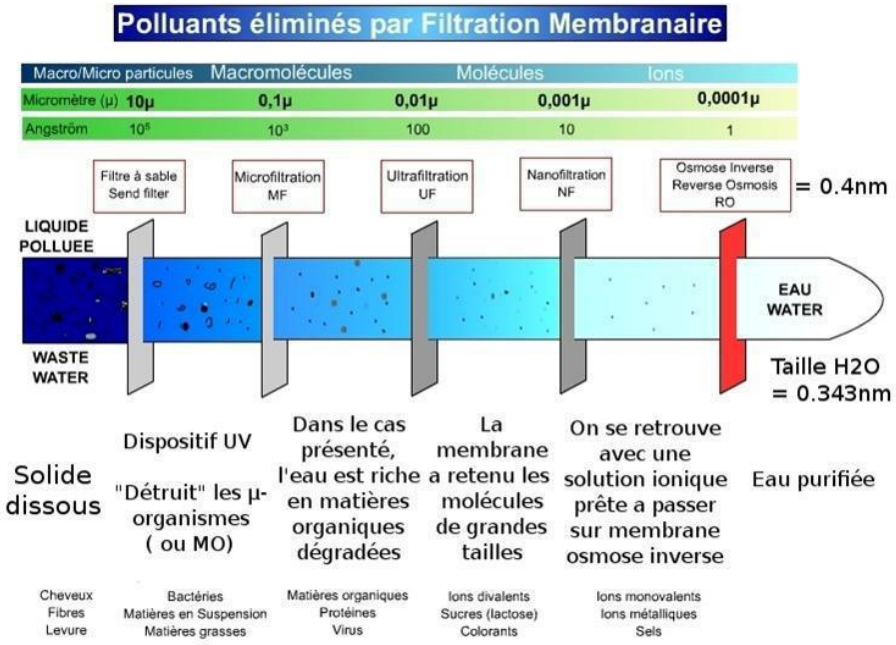


Figure I.10. Techniques de filtration membranaire (Marar Mouas 2019).

I.2.5 Caractérisations des membranes

Le taux de conversion et la sélectivité des membranes sont deux grandes notions qui permettent de caractériser les membranes (Marar et Mouas 2019) :

I.2.5.1 Taux de conversion

C'est La fraction de débit qui traverse la membrane, qu'on note y :

$$y = \frac{Q_p}{Q_r} \qquad (I.1)$$

Q_p: Le débit de la partie qui passe à travers la membrane ou perméat ($m^3 . s^{-1}$).

Q_r : Le débit de la partie appelée concentrât ou retentât qui contient les molécules ou particules retenues par la membrane ($m^3 . s^{-1}$) (Benmarak et Zahraoui 2021).

I.2.5.2 Sélectivité

Qui est définie par le taux de rejet R (ou taux de rétention) de l'espèce que la membrane est censée retenir :

$$R = \frac{C_r - C_p}{C_r} = 1 - \frac{Cp}{Cr} \qquad (I.2)$$

C_r: est la concentration de l'espèce à retenir dans la solution [g/L].

C_p : est la concentration de la même espèce dans le perméat[g/L].

L'osmose inverse utilise des membranes denses sans porosité qui laissent passer le solvant et arrêtent les ions.

I.2.5.3 Pression osmotique

On applique une pression sur la solution concentrée, la quantité d'eau transférée par osmose va diminuer. Avec une pression suffisamment forte, le flux d'eau va même s'annuler, cette pression est nommée la pression osmotique Π (en faisant l'hypothèse que la solution diluée est de l'eau pure). Si on dépasse la valeur de la pression osmotique, on observe un flux d'eau dirigé en sens inverse du flux osmotique : c'est le phénomène d'osmose inverse.

La pression osmotique peut être calculée par la loi de Van't Hof, qui exprime que la pression osmotique exercée par un soluté est égale à la pression que ce corps aurait exercé dans l'état gazeux dans le même volume (V) et à la même température (T). Si le soluté est dissocié en i ions, la pression osmotique sera i fois supérieure.

La pression osmotique d'une solution est proportionnelle à la concentration en soluté

$$\Pi = I.C.R.T \quad \text{(I.3)}$$

Π : Pression osmotique [bar]
I : Nombre d'ions dissociés dans le cas d'un électrolyte
C : Concentration molaire [mol.L^{-1}]
R : Constante des gaz parfaits [0,082 L.bar.$mol^{-1}K^{-1}$]
T : Température absolue [K] (Marar et Mouas 2019).

I.2.5.4 Transfert de solvant et de soluté

En Osmose Inverse, les transferts de solvant et de soluté se font par solubilisation - diffusion : le soluté et le solvant se dissolvent à travers la membrane et ce diffusent. Le transfert ne dépend donc plus de la dimension des particules mais de leurs solubilités dans le milieu membranaire. Les séparations sont donc d'origine chimique et sont liées au pouvoir solvant de la membrane (Benmarak et Zahraoui 2021).

I.2.5.4.1 Flux de solvant

Le flux de solvant $J_{solvant}$ (m.s^{-1}) et le débit volumique de solvant Qp (m3.s^{-1}) traversant la membrane sont donnés par les relations (Benmarak et Zahraoui 2021).

$$J_{solvant} = A.(\Delta P - \Delta\pi) \quad \text{(I.4)}$$

$$Q_P = A.S.(\Delta P - \Delta\pi) \quad \text{(I.5)}$$

A : est la perméabilité de la membrane [m.$s^{-1}.pa^{-1}$]

S : la surface de la membrane [m^2]

ΔP : la différence de pression de part et d'autre de la membrane [Pa]

ΔΠ : la différence de pression osmotique de part et d'autre de la membrane [Pa].

I.2.5.4.2 Flux de soluté

Le flux massique $J_{\text{soluté}}$ (kg. $m^{-2}.s^{-1}$) de soluté traversant la membrane est donné par la relation (Marar et Mouas 2019).

$$J_{soluté} = B.(C_r - C_p) \quad \text{(I.6)}$$

B : est la perméabilité moyenne de la membrane au soluté [m.s^{-1}]

C_r et C_p : sont respectivement la concentration en soluté de l'alimentation et du perméat de part et d'autre de la membrane [kg.m^{-3}].

I.3 Vieillissements membranaires

Les membranes de filtration sont constituées d'un polymère majoritaire et potentiellement d'additifs. Comme tout matériau polymère, les membranes peuvent interagir avec leur environnement (UV, température, milieu aqueux par exemple) et se dégrader plus ou moins rapidement. Le vieillissement peut être chimique ou physique et souvent les deux types de vieillissement cohabitent. Le vieillissement physique n'engendre pas de modification de la structure chimique mais est principalement lié aux contraintes mécaniques appliquées au matériau, ou encore aux phénomènes d'adsorption ou de diffusion de molécules. Lors du vieillissement chimique, la structure chimique évolue suite à une exposition à une température élevée, à un rayonnement ou à un agent chimique réactif par exemple. L'évolution de la structure chimique peut alors être la cause de modification des propriétés du matériau.

Au cours de leur utilisation sur site, les membranes voient certaines de leurs propriétés se modifier. Ces propriétés peuvent être :

- ✓ **Mécaniques :** l'apparition d'un nombre croissant de casses de fibres par exemple ou au contraire l'apparition de fibres plus lâches qu'a l'origine.
- ✓ **Hydrophiles :** par exemple, par la disparition des agents initialement ajoutés à la membrane en vue de faciliter le passage de l'eau à travers celle-ci.

- ✓ **Hydrauliques :** à l'image de la perméabilité, dont une diminution peut être liée à un phénomène de colmatage mais aussi à une évolution de la taille des pores de la membrane.
- ✓ **Sélectives :** la taille des pores de la membrane influe sur cette propriété et par conséquent sur la qualité sanitaire de l'eau produite.

Il convient alors de comprendre les raisons de ces évolutions dans le but d'adapter les conditions d'utilisation sur site et ainsi préserver au maximum les propriétés de la membrane dans le temps. Plusieurs raisons peuvent être à l'origine d'un vieillissement prématuré des membranes. La qualité d'eau arrivant sur les membranes peut avoir un effet néfaste : impact et/ou abrasion des membranes. La nature du colmatage peut également réduire les performances de filtration des membranes. Il est particulièrement étudié notamment à travers des stratégies de modification des membranes pour la diminution du colmatage.

En outre, les processus de nettoyage des membranes sont principalement mis en cause lors d'une dégradation des membranes de filtration.

L'utilisation de solutions de nettoyage souvent agressives, a l'image de l'hypochlorite de sodium n'est pas sans risque pour les membranes au regard de l'interaction solution(s)/matériaux (x). Par exemple Rabonni et al. 2015 montrent que la NaOCl est plus efficace en lavage que NaOH (toutes choses égales par ailleurs) mais la solution de NaOCl rend la membrane plus sensible à un colmatage ultérieur (Ravereau-Delattre 2015).

I.4 Principes du vieillissement des polymères

Le vieillissement correspond à une évolution lente et irréversible d'une ou de plusieurs propriétés du matériau à partir d'un point de référence, généralement pris dès la fin du cycle de fabrication. Cette évolution peut résulter de modifications de la structure des macromolécules qui assurent leur cohésion mécanique, de leur composition ou de sa morphologie.

Le vieillissement se traduit par une altération des propriétés fonctionnelles (aspect, résistance mécanique etc.) ou de propriétés plus spécifiques liées à une utilisation donnée (isolation électrique, perméabilité gazeuse ou liquide, protection contre le feu,…).

Les différents mécanismes responsables du vieillissement des polymères peuvent être classés en deux grandes catégories : physique ou chimique (Benmerak et Zahraoui 2022).

I.4.1 Vieillissement physique

Ce type de vieillissement correspond à tout processus conduisant à une modification des propriétés d'utilisation du matériau sans qu'il y ait modification de la structure chimique de ce dernier. Il englobe les phénomènes de vieillissement sous contrainte mécanique, les phénomènes de

relaxations, les phénomènes liés au transfert de masse (pénétration de solvants, migration d'adjuvants) et les phénomènes de surface (Benmerak et Zahraoui 2022).

I.4.2 Vieillissement chimique

Il correspond à tout phénomène impliquant une modification chimique du matériau sous l'influence de son environnement d'usage. Dans la pratique, ce vieillissement se superpose le plus souvent au vieillissement physique et les deux phénomènes interfèrent. Le vieillissement chimique comprend (Verdu 2002) :

I.4.2.1 Vieillissement thermochimique

Qui correspond à tout vieillissement chimique en atmosphère inerte (thermolyse) ou dans l'air (thermo oxydation), dont la cinétique dépend essentiellement d'un paramètre externe qui est la température. Pour le cas particulier de la dégradation à des températures très élevées, on parle de pyrolyse (Benmerak et Zahraoui 2022).

I.4.2.2 Vieillissement photochimique

C'est-à-dire le vieillissement résultant de l'exposition directe au rayonnement solaire. L'acte primaire de tout processus photochimique est l'absorption d'un photon. Cette absorption va amener l'espèce absorbante A à l'état excité [A]*, c'est-à-dire à un niveau électronique d'énergie plus élevée, conférant à la molécule une réactivité qu'elle n'a pas à l'état fondamental.

$A + h\nu \rightarrow [A]^*$ $\quad\quad$ $avec\ h\nu$: l'énergie du photon

La grande majorité des polymères n'absorbent pas dans l'UV c'est-à-dire à des longueurs d'onde supérieures à 300 nm. Le vieillissement photochimique est alors lié à la réactivité de défauts de structure et d'impuretés absorbantes qui induisent celle du polymère (Benmerak et Zahraoui 2022).

I.4.2.3 Vieillissement hydrolytique

S'accompagnant d'une hydrolyse, entraîne des coupures statistiques des chaînes macromoléculaires du polymère, d'où une altération, à terme, des propriétés mécaniques. La réaction est généralement très lente à température ambiante, la vitesse de l'action chimique élémentaire étant elle-même faible et le processus étant le plus souvent contrôlée par la diffusion (également lente) de l'eau dans le matériau (Benmerak et Zahraoui 2022).

I.4.2.4 Vieillissement radiochimique

Par des radiations ionisantes de forte énergie (X, α, β, γ, neutrons). D'autres types de vieillissement chimique peuvent exister. On peut citer par exemple le vieillissement en milieu réactif, le vieillissement biochimique, le vieillissement sous contrainte mécanique conduisant à des coupures de chaines (mécano chimique).

Les processus communs à tous les types de vieillissement chimique, sont les suivants :

- **Les coupures statistiques des chaînes :** le processus de la coupure dépend de l'énergie de dissociation des liaisons chimiques dans la structure qui correspondent à la création de deux chaînes polymères à partir d'une seule (Figure I.11) (Verdu 1990).

  Le terme « statistique » ne correspond pas nécessairement à la réalité, il est utilisé car il fait partie de la terminologie courante "Radom Chain scission".

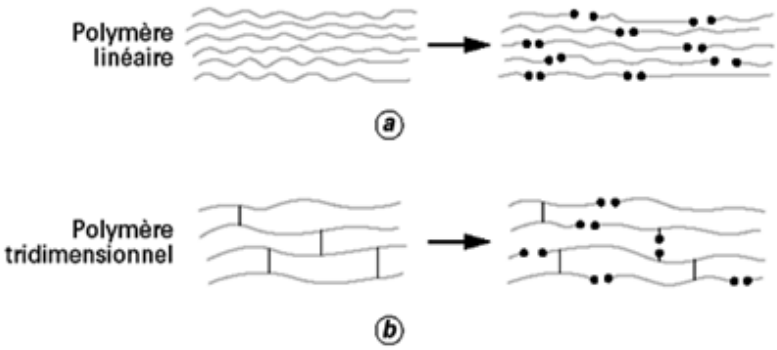


Figure I.11. Processus de coupure statistique des squelettes macromoléculaires (Verdu 1990).

La réticulation : c'est le processus inverse de la coupure de chaines. Il se traduit par une augmentation de la masse moléculaire à cause de la création d'une seule "grande" chaine à partir de deux chaines polymères (Figure I.12) (Verdu 2002).

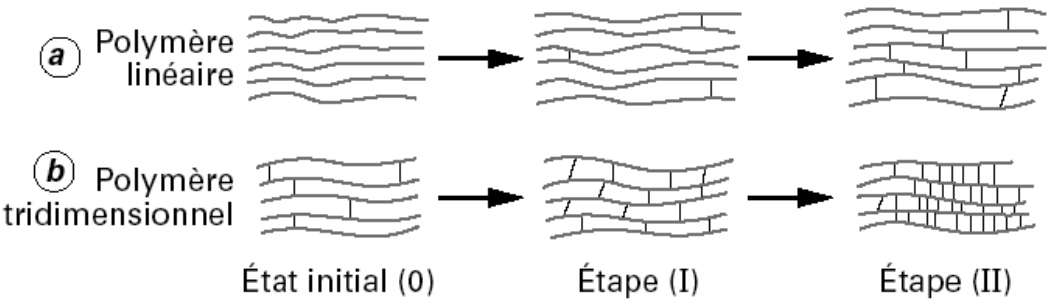


Figure I.12. Processus de réticulation dans un polymère initialement linéaire et dans un polymère initialement tridimensionnel (Verdu 2002).

Si certains polymères réagissent essentiellement par coupures de chaines (poly méthacrylate de méthyle (PMMA), polypropylène (PP), poly oxyde méthylène (POM)…), d'autres, par contre, peuvent subir simultanément des coupures de chaines et des réticulations (polyéthylène (PE), polychlorure de vinyle (PV), nombreux polymères tridimensionnels). Leurs propriétés évoluent alors en fonction de la part relative de chacun des processus.

▪ **Les réactions de dépolymérisation** qui sont, comme leur nom l'indique, l'inverse des réactions de polymérisation. Elles font donc intervenir une élimination séquentielle de molécules de monomère, à partir d'un site particulièrement instable préexistant (par exemple une extrémité de chaîne) ou résultant d'une coupure statistique.

▪ **Les réactions conservant le squelette macromoléculaire :** pour des taux d'avancement relativement faibles, ces réactions n'ont pratiquement aucun effet sur les propriétés mécaniques, mais peuvent affecter d'autres propriétés des polymères, essentiellement les propriétés électriques et optiques. Ce type de réactions se produit essentiellement au niveau des groupements latéraux par leur modification, l'élimination et la formation de doubles liaisons ou par cyclisation intramoléculaire comme la montre la figure I.13 (Benmerak et Zahraoui 2022).

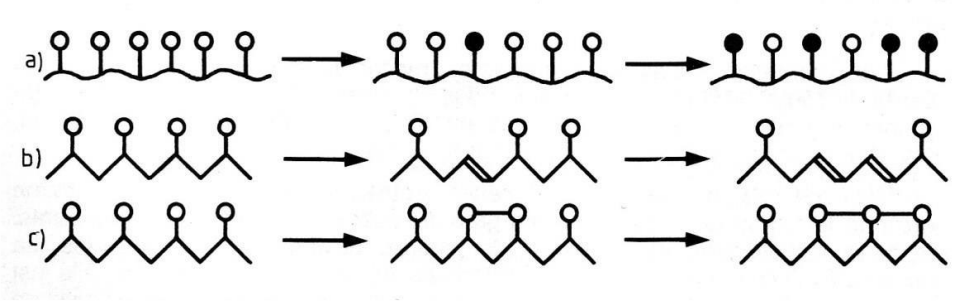


Figure I.13. Principaux types de réactions conservant le squelette macromoléculaire (a) modification des groupements latéraux, (b) élimination de groupements latéraux et formation de doubles liaisons et (c) cyclisation intramoléculaire (Benmerak et Zahraoui 2022).

I.5 Vieillissement chimique de membranes par exposition à du chlore

Au cours de son utilisation en exploitation, une membrane d'osmose inverse en polyamide aromatique (PA) est susceptible de réagir avec les différents agents de nettoyages, génériques ou formulés, couramment utilisés lors du prétraitement ou pour le nettoyage de la surface de membranes. Benavente et al. 2004 ont considéré la réaction d'hydrolyse de fonctions carbonyle du groupement amide par exposition de membranes sur plus de 24 heures à des concentrations de 1 M de différents acides (acide chlorhydrique et nitrique) et base fortes (chlorure de sodium). Les travaux de Nilsson

et al. 2008 ont évalué la transformation des propriétés en transfert de membranes exposées à un agent formulé basique, l'Ultrasil, à des températures élevées supérieures à 30 °C.

Ces études montrent que les cycles de nettoyage de membranes d'osmose inverse, lorsque réalisés dans des conditions sévères de pH et température, hors des limites recommandées par le fabricant, peuvent engendrer des transformations irréversibles de propriétés de la couche active et affecter sa sélectivité, par un vieillissement chimique.

Le vieillissement chimique correspond à une modification de la structure chimique d'un polymère, point de départ d'une transformation irréversible, en condition d'utilisation, de ses propriétés. Les principaux processus de vieillissement chimique comportent la réaction au sein du squelette macromoléculaire, engendrant généralement une coupure/affaiblissement statistique de liaisons covalentes et interactions non covalentes, et la réaction sur des groupements latéraux

La réactivité du PA avec du chlore, particulièrement au chlore actif, est un cas avéré de vieillissement chimique de ce polymère. Les fabricants de membrane recommandent de limiter l'exposition à du chlore à des concentrations inférieures à 0,1 $mg.L^{-1}$.

La chloration, réaction de substitution du chlore, de la couche active est bien documentée et ses effets connus des exploitants. Le vieillissement chimique du polyamide aromatique par chloration est commenté au regard des sites réactifs potentiels et des mécanismes impliqués (Benmerak et Zahraoui 2022).

I.6 Modification des propriétés de transfert de membranes lors de vieillissement chimique

Kang et al. 2007 ont suivi la capacité de rétention et la variation du flux lors de l'osmose inverse d'une solution de chlorure de sodium (NaCl) de 2000 mg.L-1 de membranes polyamide composite immergées dans des bains de javel en fonction du temps d'exposition et du pH. Une perte de rétention en sels de 7% est observée après une exposition de 20 h pour une concentration en chlore libre de 100 ppm (dose cumulée de 2000 ppm.h) et de 54 h pour une concentration de 10 ppm. Les conditions les plus dégradantes qu'ils ont identifiées sont un pH 4,0 et une dose de 2000 ppm.h. Dans ces conditions, la chute du flux atteint 80%, et diminue de 70% dès la première heure d'exposition. De plus, Kwon et al. 2006 mettent en évidence l'influence du pH sur l'augmentation de la perméabilité de membranes d'OI chlorées. Ils suggèrent pour des conditions d'exposition à pH acide (pH 4,0), les plus sévères, que les chaines du PA de membranes exposées à des doses croissantes de chlore sont :

- ✓ sensibles au compactage durant la filtration d'eau UP à 15 bar
- ✓ capables de se réarranger dans une structure thermodynamiquement stable avec le transfert d'eau à pression constante de 15 bar pour des durées de filtration prolongées.

La sensibilité des chaines du PA aux conditions de filtration est attribuée par ces travaux à un degré de liberté de la rotation des liaisons N-Cl (isomères cis-trans identifiés par et à la baisse de rigidité des chaines du PA par affaiblissement de liaisons H.

Une altération de la sélectivité de membranes NF et OI a également été observée et suivie à l'échelle pilote par osmose inverse d'une eau de surface réelle sur des durées de fonctionnement et pour des conditions d'exposition au chlore, à des concentrations de 10 à 30 $mg.L^{-1}$, prolongées.

Des analyses divergentes de propriétés interfaciales, dont la rugosité et hydrophile de surface sont données dans la bibliographie. Elles semblent indiquer qu'une mobilité accrue des chaines du PA soit à l'origine des transformations des propriétés de transfert de membranes (Benmerak et Zahraoui 2022).

I.7 Conclusion

Les études montrent que les cycles de nettoyage des membranes, lorsque réalisés dans des conditions sévères de pH et température, hors des limites recommandées par le fabricant, peuvent engendrer des transformations irréversibles de propriétés de la couche active et affecter sa sélectivité, par vieillissement chimique. Le vieillissement chimique du polymère par chloration est commenté par la pression appliquée, le temps de filtration, la dose "HOCl", pH et température. Le vieillissement chimique de membrane dépend de la mobilité des chaines du polyamide aromatique "PA" qui semble être décrit par des modifications de la perméabilité à l'eau et de soluté et la rétention des molécules organiques et inorganiques.

Chapitre II. Réseaux de Neurones Artificiels

II.1. Introduction

Les réseaux de neurones connaissent depuis quelques années un succès croissant dans divers domaines des sciences de l'ingénieur, celui du génie des procédés n'échappe pas à cette règle.

Dans un premier temps, nous rappelons les définitions et notations de bases relatives aux réseaux de neurones. Nous poursuivons en exposant les types et la méthodologie d'apprentissage. Nous présentons aussi, d'une manière générale, les étapes de conception d'un réseau de neurones : le choix des entrées et des sorties, l'élaboration de la base de données et de la structure du réseau…etc.

II.2. Historique

Les premiers à proposer un modèle sont deux américains de Chicago, le neurophysiologiste Warren McCullers et le logicien Walter Pitt, qui inventent en1943 le premier neurone formel qui portera leurs noms (neurone de McCullers- Pitt). Quelques années plus tard en 1949, Heb propose une formulation du mécanisme d'apprentissage, sous la forme d'une règle de modification des connexions synaptiques. Cette règle repose sur le fait que si deux neurones sont connectés entre eux et activées au même temps, les connexions qui les relient doivent être renforcées, dans le cas contraire, elles ne sont pas modifiées. Le premier réseau de neurones artificiels apparaît en 1958, grâce aux travaux de Frank Rosenblatt qui conçoit le fameux perceptron. Le perceptron possède une couche de neurones d'entrée, ainsi qu'une couche de sortie. Ce réseau parvient à apprendre à identifier des formes simples et à calculer certaines fonctions logiques, à la fin des années 60 (1969) Rosenblatt à reçut une critique violente par Marvin Minsky et Seymour Papert, qui publient un livre dans lequel ils décrivent une série de problèmes de reconnaissance des forme qu'un perceptron ne peut pas résoudre, problème dit d'un apprentissage difficile. Les travaux sur la technologie des réseaux neuronaux sont alors quasiment interrompus, il faudra alors attendre le début des années 80 (1982) pour que Hopfield démontre l'intérêt d'utiliser des réseaux récurrents "feed-back".

En parallèle des travaux de Hopfield, Werbos conçoit son algorithme de rétropropagation de l'erreur, qui offre un mécanisme d'apprentissage pour les réseaux multicouches de type perceptron (MLP), fournissant ainsi un moyen d'entraîner les neurones des couches cachées. Cet algorithme de 'back- propagation' ne sera pourtant popularisé qu'en 1986 par Rumelhart (Laidi 2009).

II.3. Réseaux de neurones artificiels (RNA)

II.3.1. Neurone biologique

L'idée de réseaux de neurones artificiels a été inspirée de la manière par laquelle les neurones biologiques traitent les informations. Le cerveau humain est composé de cellules distinctes appelées neurones formant un ensemble dense d'environ 10 à 100 milliards d'unités interconnectées. Tel qu'il est illustré sur la figure II.1, le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former les dendrites. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma (corps du neurone).

L'information est traitée alors par le corps cellulaire. Si le potentiel d'action dépasse un certain seuil, le corps cellulaire répond par un stimulus. Le signal transmis par le neurone est cheminé ensuite le long de l'axone (unique) pour être transmis aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones s'appelle synapse (Benmerak et Zahraoui 2022).

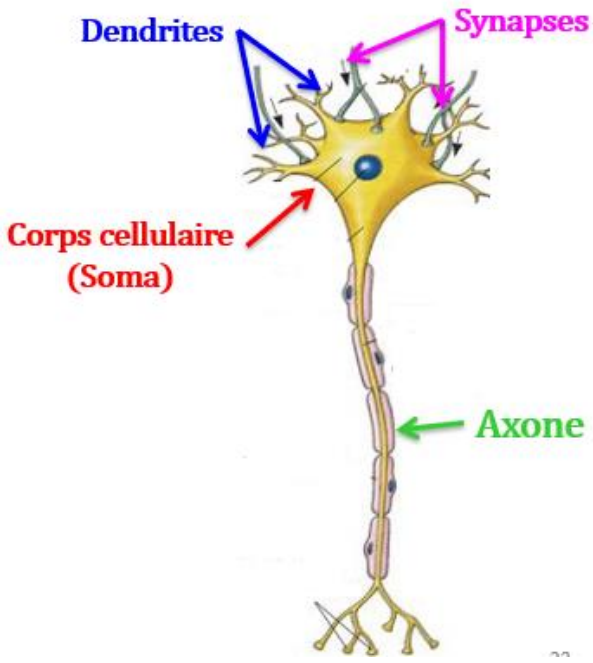


Figure II.1. Neurone biologique (Ammi et al. 2021).

II.3.2. Neurone formel

Le neurone formel est l'élément essentiel d'un réseau de neurones. C'est un opérateur mathématique très simple, dont on peut facilement calculer la valeur numérique. Son fonctionnement est schématisé sur la figure II.2.

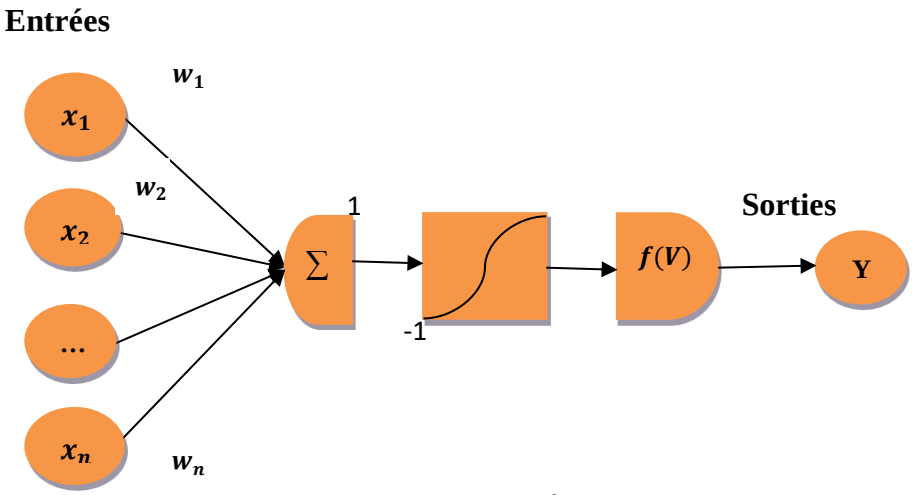


Figure II.2. Neurone formel (Ammi 2016).

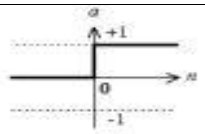
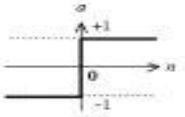
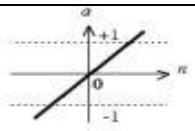
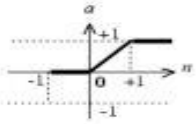
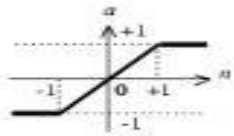
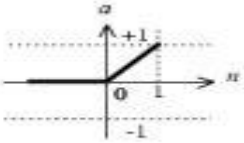
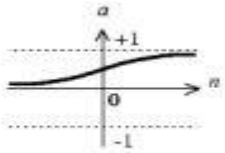
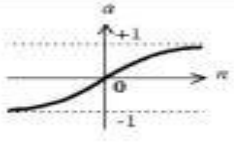
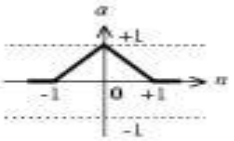
Un neurone formel est une fonction algébrique paramétrée, non linéaire en ses paramètres. Ses entrées peuvent être les sorties d'autres neurones ou des entrées de signaux extérieurs. Sa sortie est une fonction non linéaire *f* d'une combinaison linéaire *v* des entrées (x_i). Le potentiel *v* le plus fréquemment utilisé est la somme pondérée des entréesx_i pondérées par les coefficients (w_i) également appelés poids de connexions :

$$v = w_0 + \sum_{i=1}^{n} (w_i x_i) \qquad \text{(II. 1)}$$

Précisons que le poids $w_0$est affecté à une entrée constante appelée "biais". Une fonction *f*, appelée fonction d'activation, est appliquée à ce potentiel *v*. Le choix d'une fonction d'activation se révèle dans certains cas être un élément constitutif important des réseaux de neurones. Les fonctions mathématiques les plus souvent utilisées dans notre travail sont regroupées dans le tableau II.1. À la différence des neurones biologiques dont l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs possibles comprises dans l'intervalle [0, +1] ou [-1, +1]. Un neurone formel, réalise donc l'opération suivante (Benmerak et Zahraoui 2022) :

$$y = f(v) = f\left(w_0 + \sum_{i=1}^{n} (w_i x_i)\right) \qquad \text{(II. 2)}$$

Tableau II.1. Fonctions de transfert usuelles, a=f(n) (Khaouane 2013).

Nom de la fonction	**Relation entrée / sortie**	**Graphe de la fonction**	**Fonction MATLAB® correspondante**
Seuil	a = 0 si n < 0 a =1 si n ≥ 0		hardlim
Seuil symétrique	a = −1 si n < 0 a =1 si n ≥ 0		hardlims
Linéaire	a = n		purelin
Linéaire saturée	a = 0 si n < 0 a = n si 0 ≤ n ≤1 a =1 si n > 1		satlin
Linéaire saturée symétrique	a = −1 si n < −1 a = n si −1≤ n ≤1 a =1 si n >1		Satlins
Linéaire positive	a = 0 si n < 0 a = n si n ≥ 0		Poslin
Logistique (Sigmoïde logarithmique)	$a = \frac{1}{1+e^{-n}}$		Logsig
Tangente hyperbolique	$a = \frac{e^{+n}-e^{-n}}{e^{+n}+e^{-n}}$		tansig=
Triangulaire de base	a = 1-|n| , -1≤ n ≤ +1 a=0 , autrement		Tribas

II.3.3. Architecture d'un réseau de neurones

Un RNA est formé d'un ensemble de neurones formels interconnectés. Deux grands types d'architectures peuvent être distingués (Benmerak et Zahraoui 2022) :

- **Les réseaux de neurones non bouclés :** Ils réalisent une (ou plusieurs) fonction(s) algébrique(s) des entrées, par composition des fonctions réalisées par chaque neurone. Les réseaux de neurones non bouclés sont des outils statiques utilisés principalement pour effectuer des tâches d'approximation de fonctions non linéaires, de modélisation de processus statiques non linéaires. La figure II.3 illustre la structure de ce type de réseau.

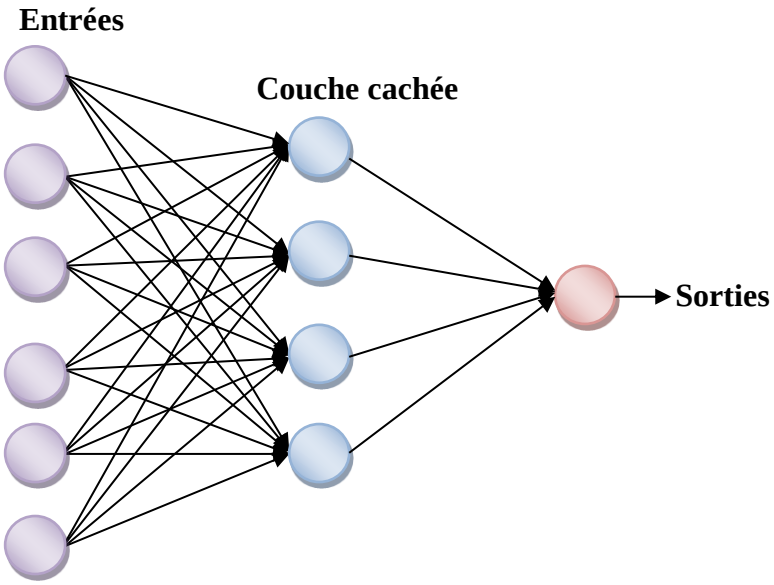


Figure II.3. Structure d'un réseau de neurones non bouclé (Benmerak et Zahraoui 2022).

- **Les réseaux de neurones bouclés :** Ils constituent quant à eux un système dynamique "à temps discret", régi par une (ou plusieurs) équation(s) aux différences non linéaires, résultant de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions. Ils sont utilisés pour effectuer des tâches de modélisation et d'adaptation de systèmes dynamiques, de commande de processus ou de filtrage.

Un réseau de neurones bouclé est schématisé par un graphe de connexions qui est cyclique. Lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de "cycle"). Ainsi, un retard entier multiple de l'unité de temps choisie est attaché à chaque connexion d'un réseau de neurones bouclé (ou à chaque arrête de son graphe). Une grandeur à un instant donné ne peut pas être fonction de sa propre valeur au même instant. Tout cycle du graphe du réseau doit avoir un retard non nul (Khaouane 2013).

La figure II.4 représente un exemple de réseau de neurones bouclé. Les chiffres dans les carrés indiquent le retard attaché à chaque connexion, exprimé en multiple de l'unité de temps. Ce réseau contient un cycle, qui part du neurone 3 et revient à celui-ci en passant par le neurone 4. La connexion de 4 vers 3 ayant un retard d'une unité de temps.

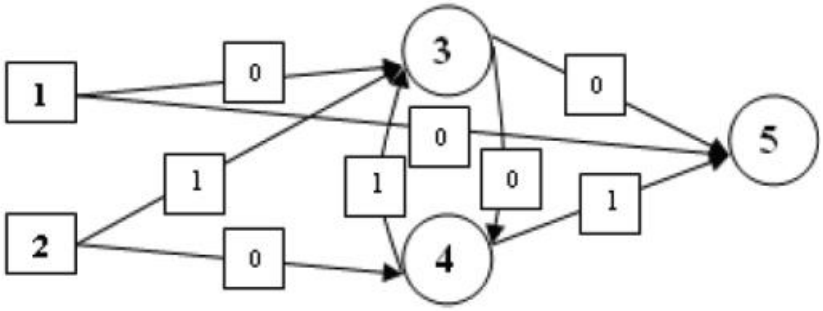


Figure II.4. Structure d'un réseau de neurones bouclé (récurent) (Khaouane 2013).

II.3.4. Apprentissage des réseaux de neurones

On appelle apprentissage, l'opération par laquelle le réseau de neurones acquiert la capacité de réaliser certaines tâches en modifiant les paramètres internes (poids synaptique), cette modification se fait en utilisant un algorithme d'adaptation paramétrique appelé "algorithme d'apprentissage".

L'apprentissage consiste alors à améliorer les performances futures du réseau en se basant sur les expériences acquises.

Plusieurs modes d'apprentissage peuvent être distinguées, ceux-ci se différencient principalement par le type d'exemples disponible pour un RNA, l'apprentissage peut être considéré comme le problème de la mise à jour des poids des connexions au sein du réseau, afin de réussir la tâche qui lui est demandée. L'apprentissage est la caractéristique principale des RNA et il peut se faire de différentes manières et selon différentes règles.

L'objectif des algorithmes d'apprentissages est de minimiser l'erreur de décision effectuée par le RNA en ajustant les poids à chaque présentation d'un vecteur d'entraînement (Laidi 2006).

Les algorithmes d'apprentissages peuvent se répartir en trois classes :

- Apprentissage non supervisé.
- Apprentissage forcé ou imposé.
- Apprentissage supervisé.

II.3.4.1. Apprentissage non supervisé

Cet entraînement se fait sur la base d'informations locales existant à l'entrée. Il représente la capacité des réseaux de neurones à apprendre sana connaître la sortie désirée. Dans ce cas, le réseau organise lui-même les entrées qui lui sont présentées de façon à minimiser un critère de performance donné. Les informations d'entrée sont présentées au réseau et des catégories internes sont formées par une auto organisation du réseau. Cet apprentissage est dit aussi compétitif du moment où il y a une compétition entre les unités du réseau à représenter le vecteur d'entrée (Laidi 2006). La figure II.5 montre le principe de l'apprentissage non supervisé.

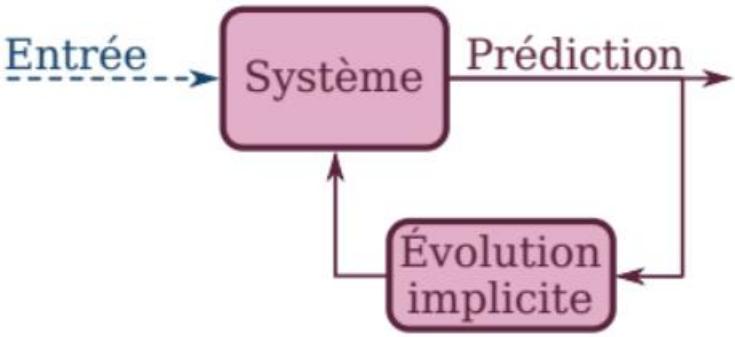


Figure II.5 Principe de l'apprentissage non supervisé (Kherbache et Ben labiod 2022).

II.3.4.2. Apprentissage supervisé

L'apprentissage supervisé (Figure II.6) correspond au cas où l'on dispose d'exemples d'entrées et de sorties simultanément (c'est-à-dire les entrées et les sorties désirées correspondantes). On cherche alors à construire un modèle capable de prédire et donner la valeur de la sortie désirée connaissant celle de l'entrée et fournit un signal d'erreur quand une erreur est établie ; en minimisant celle-ci, on a un outil d'optimisation des paramètres internes du réseau qui sont les poids synaptiques. Cette procédure est répétée jusqu'à qu'un critère de performance soit satisfait (Laidi 2006).

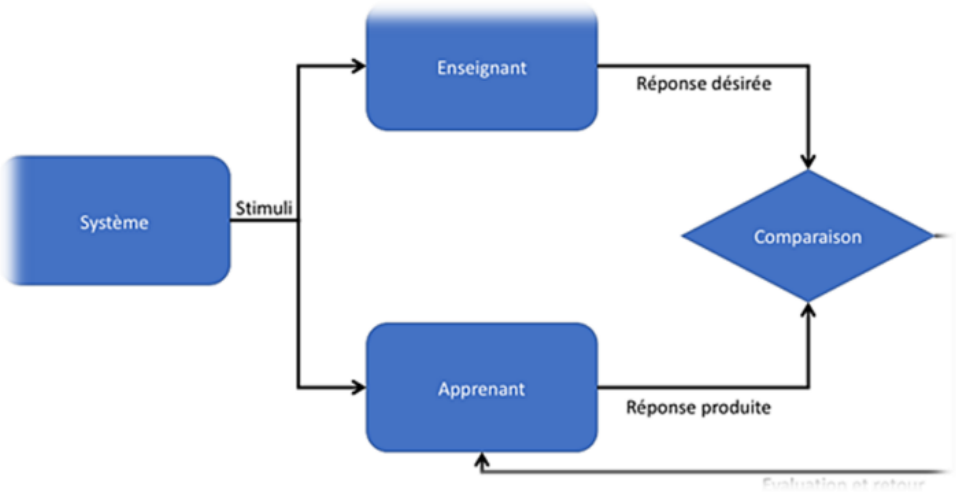


Figure II.6 Principe de l'apprentissage supervisé (Kherbache et Ben labiod 2022).

II.3.4.3. Apprentissage forcé ou imposé

Dans cet apprentissage on indique seulement au réseau si la sortie est bonne ou mauvaise en induisant ainsi une variation sélective des poids de connexions (Laidi 2009).

II.4. Réseaux de neurones les plus utilisés

Un RNA est formé d'un ensemble de neurones formels interconnectés. Deux grands types d'architectures peuvent être distingués (Figure II.7) :

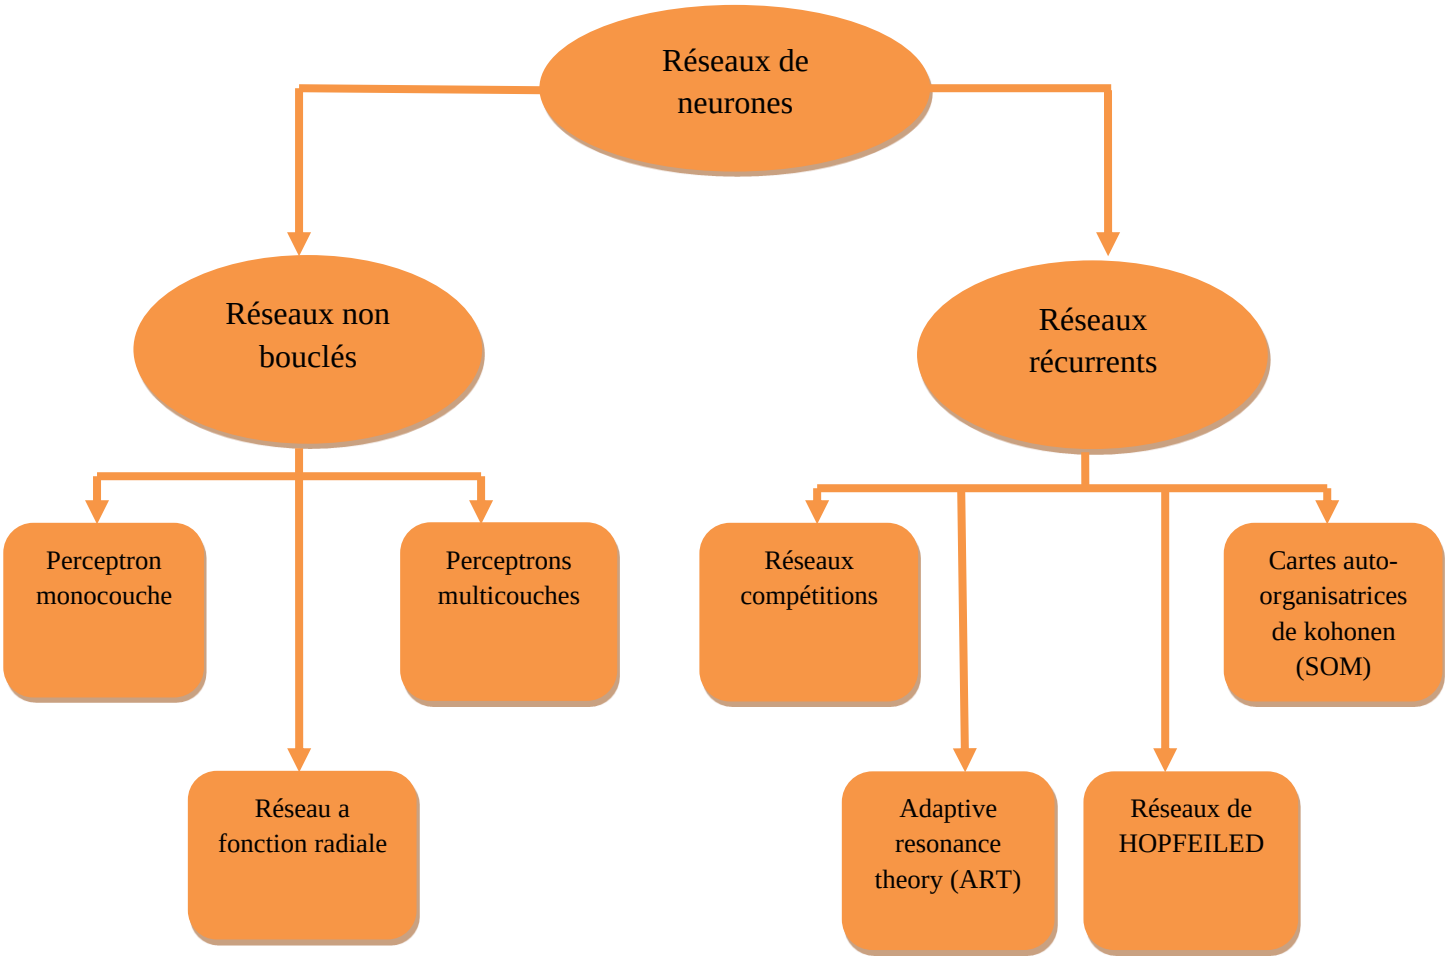


Figure II.7. Réseaux de neurones les plus utilisés.

II.4.1. Perceptron monocouche (perceptron simple)

Le perceptron est le premier modèle des réseaux de neurones inventés en 1957 par Frank Rosenblatt (Rosenblatt 1958). C'est un réseau simple, puisqu'il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il peut aussi être utilisé pour faire de la classification et pour résoudre des opérations logiques simples, il suit généralement un apprentissage supervisé (Talbi 2011).

II.4.2. Perceptron multicouche (en anglais Multi Layer Perceptron)

Le PMC est un réseau de neurones non bouclé caractérisé par une structure bien particulière. Ces neurones sont organisés en couches successives où les informations circulent dans un seul sens, de la couche d'entrée vers la couche de sortie. Les neurones d'une même couche ne sont pas interconnectés. Un neurone ne peut envoyer son résultat qu'à un neurone situé dans une couche postérieure à la sienne. Le réseau est formé de plusieurs couches, qui s'appellent, par convention :

- **Couche d'entrée :** cette couche représente toujours une couche associée aux entrées du système, composée des cellules d'entrée qui correspondent aux k variables d'entrée.
- **Couche(s) cachée(s) :** chaque couche est composée de p neurones. Ces neurones n'ont aucun lien avec l'extérieur et sont appelés neurones cachés.
- **Couche de sortie :** elle est constituée par la valeur de sortie de la combinaison linéaire des fonctions de transferts de la couche cachée.

Les neurones sont reliés entre eux par des connexions pondérées. Ce sont les poids de ces connexions qui gouvernent le fonctionnement du réseau et programment une application de l'espace des entrées vers l'espace des sorties, à l'aide de la transformation non linéaire (Benmerak et Zahraoui 2022).

Dans notre étude, nous avons adopté le modèle le plus couramment utilisé, le Perceptron Multi-couches (PMC), illustré par la figure II.3 et dont les principes sont exposés dans ce qui suit.

II.4.3. Réseaux à fonction radiale

Les réseaux à fonction de bases radiales (RFR) ou plus simplement réseaux à bases radiales ont été proposés par Moody et Darren (Moody et Darren 1989). Les RFR seront donc employés dans les mêmes types de problèmes que les perceptrons multicouches à savoir, en classification et en approximation de fonctions, particulièrement. L'apprentissage le plus utilisé pour les RFR est le mode hybride (Talbi 2011).

II.4.4. Cartes auto-organisatrices de Kohonen (SOM)

Les cartes topologiques ou cartes auto organisatrices ont été introduites pour la première fois par Kohonen en 1982 (Kohonen 1982). Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topo-logiquement, en fonction de patterns d'entrée. Le réseau forme ainsi une sorte de treillis dont chaque nœud est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins, vont être modifiés afin d'augmenter encore cette corrélation (Talbi 2011).

II.4.5. Réseaux de Hop Field

Les réseaux de Hop Field (Hop Field 1982) sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune différence entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non-linéaire et sont capables de trouver un objet stocké en fonction de représentations

partielles ou bruitées. L'application principale des réseaux de Hop Field est l'entrepôt de connaissances, mais aussi la résolution de problèmes d'optimisation. Le mode d'apprentissage utilisé ici est le mode non-supervisé (Talbi 2011).

II.4.6. Réseaux ART

Les réseaux ART (en anglais Adaptive Résonance Theory) sont des réseaux à apprentissage par compétition (Carpenter et Gross berg 1987; Carpenter et Gross berg 1988). Dans ce genre de réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche d'un prototype déjà connu par le réseau. Il est à noter qu'il existe deux principaux types de réseaux ART : les ART-1 pour des entrées binaires et les ART-2 pour des entrées continues. Le moded'apprentissage des ART peut être supervisé ou non (Talbi 2011).

II.5. Conception d'un modèle neuronal

Les réseaux de neurones réalisent des fonctions non linéaires paramétrées. Leurs mises en œuvre nécessitent :

- La détermination des entrées et des sorties pertinentes, c'est-à-dire les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser ;
- La construction de la base de données et le choix des échantillons ;
- La détermination du nombre de neurones cachés nécessaires pour obtenir une approximation satisfaisante ;
- La réalisation de l'apprentissage ;
- L'évaluation des performances du réseau de neurones à l'issue de l'apprentissage (Khaouane 2013).

II.5.1. Détermination des entrées/sorties du réseau de neurones

Pour toute conception de modèle, la sélection des entrées doit prendre en compte deux points essentiels :

- Premièrement, la dimension intrinsèque du vecteur des entrées doit être aussi petite que possible, en d'autres termes, la représentation des entrées doit être la plus compacte possible, tout en conservant pour l'essentiel la même quantité d'information et en gardant à l'esprit que les différentes entrées doivent être indépendantes.

- En second lieu, toutes les informations présentées dans les entrées doivent être pertinentes pour la grandeur que l'on cherche à modéliser : elles doivent donc avoir une influence réelle sur la valeur de la sortie (Khaouane 2013).

II.5.2. Construction de la base de données et choix des échantillons

Le processus d'élaboration d'un réseau de neurones commence par la construction d'une base de données et le choix des échantillons. Il faut donc déterminer les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser.

Cette étape est cruciale et aide à déterminer le type de réseau le plus approprié pour résoudre un problème donné. En particulier, la façon dont se présente l'échantillon conditionne le type de réseau, le nombre de cellules d'entrée et de sortie et la façon dont il faudra mener l'apprentissage, le test et la validation (Bishop 1995).

Afin de développer une application à base de réseaux de neurones, il est nécessaire de disposer de deux bases de données, une pour effectuer l'apprentissage et l'autre pour tester le réseau obtenu et déterminer ses performances.

Pour mieux contrôler la phase d'apprentissage, il est souvent préférable de posséder une troisième base de données appelée "base de validation croisée" (Stone 1977). Les avantages liés à l'utilisation de cette troisième base de données seront exposés dans les paragraphes suivants. Notons qu'il n'y pas de règle pour déterminer ce partage d'une manière quantitative, néanmoins chaque base doit satisfaire aux contraintes de représentativité de chaque classe de données et doit généralement refléter la distribution réelle, c'est-à-dire la probabilité d'occurrence des diverses classes

Généralement, les bases de données subissent un prétraitement qui consiste à effectuer une normalisation appropriée tenant compte de l'amplitude des valeurs acceptées par le réseau. Les valeurs d'entrées et de sortie sont normalisées dans un intervalle spécifique afin de donner à chaque paramètre la même influence statistique. De plus, un problème additionnel peut survenir à cause d'une possible saturation de la sortie, si la somme pondérée des entrées du perceptron multicouche($\sum(w_i x_i)$) est dans la partie asymptotique de la fonction d'activation (Khaouane 2013).

II.5.3. Définition de la structure du réseau

La détermination de l'architecture optimale est restée pendant longtemps un problème ouvert. Il existe actuellement diverses méthodes empiriques mettant notamment en jeu des tests statistiques pour une vaste classe de réseaux.

Comme nous l'avons mentionné, nous avons retenu le perceptron multicouche comme base du modèle. Nous structurons ce réseau en précisant le nombre de couches et de neurones cachés pour que le réseau soit en mesure de reproduire ce qui est déterministe dans les données.

II.5.3.1. Nombre de couches cachées

Mis à part les couches d'entrée et de sortie, il faut décider du nombre de couches intermédiaires ou cachées. Sans couche cachée, le réseau n'offre que de faibles possibilités d'adaptation. Néanmoins, il a été démontré qu'un perceptron multicouche avec une seule couche cachée pourvue d'un nombre suffisant de neurones, peut approximer n'importe quelle fonction avec la précision souhaitée

II.5.3.2. Nombre de neurones cachés

Chaque neurone peut prendre en compte des profils spécifiques de neurones d'entrée. Un nombre plus important permet donc de mieux "coller" aux données présentées, mais diminue la capacité de généralisation du réseau. Il faut alors trouver le nombre adéquat de neurones cachés nécessaire pour obtenir une approximation satisfaisante. Le nombre de neurones cachés dépend du type de données dont on dispose. En général, ce nombre est déterminé par des règles empiriques. Suivant les auteurs, la taille de la couche cachée doit être (Dames 2005) :

- Soit égale à celle de la couche d'entrée ;
- Soit égale à 75 % de celle-ci
- Soit égale à la racine carrée du produit du nombre de neurones dans la couche d'entrée et de sortie.

Pour des cas plus sophistiqués, la recherche consisterait soit à :

- Estimer un réseau comportant de nombreux neurones puis à le simplifier par l'analyse des multi-Colinéarités ou par une règle d'apprentissage éliminant les neurones inutiles (Dames 2005) ;
- Définir une architecture tenant compte de la structure des variables identifiées au préalable par une analyse en composantes principales ;
- Augmenter progressivement la complexité du modèle à chaque itération, dite "Cascadant", et réévaluer l'efficacité de généralisation à chaque addition d'un nouveau neurone (Khaouane 2013).

II.5.4. Apprentissage

Une fois l'architecture choisie, elle doit subir une phase d'apprentissage. Cette dernière consiste à calculer les coefficients synaptiques de telle manière que les sorties du réseau de neurones

soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties "désirées". Celles-ci correspondent à la valeur de la fonction que l'on veut approcher ou à la sortie du processus que l'on veut modéliser.

L'apprentissage correspond donc à la phase du développement du réseau durant laquelle les coefficients synaptiques sont modifiés jusqu'à l'obtention du comportement désiré.

Dans notre étude, comme nous disposons des valeurs de sortie, nous avons choisi l'apprentissage supervisé, mettant en jeu un algorithme d'optimisation. Ce dernier cherche à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées.

Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût : le gradient est estimé par une méthode spécifique, dite la règle du gradient de l'erreur (en anglais delta Rule). C'est une des règles les plus utilisées pour l'apprentissage supervisé de réseaux de neurones. Initialement développée pour résoudre des problèmes de traitements adaptatifs du signal, elle a conduit ensuite à un algorithme connu sous le nom de l'algorithme de rétropropagation du gradient de l'erreur (en anglais Back-propagation). On distingue deux étapes dans la phase d'apprentissage :

- **Une phase de propagation**, qui consiste à présenter une configuration d'entrée au réseau, puis à la propager à celle de sortie en passant par les couches cachées.
- **Une phase de rétropropagation**, qui consiste, après le processus de propagation, à minimiser l'erreur commise sur l'ensemble des exemples présentés, erreur considérée comme une fonction des poids synaptiques. Cette erreur représente la somme des différences au carré entre les réponses calculées et celles désirées pour tous les exemples contenus dans l'ensemble de l'apprentissage.

Les algorithmes de rétropropagation implantés actuellement dans les logiciels de RNA appartiennent à une des cinq classes suivantes (Khaouane 2013):

- Descente du gradient ;
- Descente des gradients conjugués ;
- Quasi-Newton ;
- Levenberg-Marquardt ;
- Régularisation

Le tableau I.2 résume les algorithmes d'apprentissage par rétropropagation implanté dans la boite à outils des RN du programme MATLAB® (Demuth et Beadle 2000).

Tableau I.2. Résumé des caractéristiques des algorithmes d'apprentissage de rétropropagation implantés dans MATLAB® (Demuth et Beadle 2000).

Algorithme	Caractéristiques
Descente du gradient	
Descente du gradient simple (**tradingd**)	Descente du gradient de base. Réponse lente ; peut être utilisée pour apprentissage en mode séquentiel
Descente du gradient avec moment (**traingisme**)	Descente du gradient avec moment. Le moment permet à un réseau de répondre non seulement au gradient local, mais aussi aux tendances récentes dans la surface d'erreur. Sans moment un réseau peut être coincé dans un minimum local peu profond. Plus rapide que traingd, ne peut être utilisée que pour apprentissage en mode séquentiel
Descente du gradient avec taux d'apprentissage variable (**traingda**)	Taux d'apprentissage variable. Plus rapide que traingd, mais ne peut être utilisée que pour apprentissage en mode batch. Utilise des règles heuristiques pour la variation du taux d'apprentissage
Descente du gradient avec moment et taux d'apprentissage variable (**traingdx**)	Descente du gradient avec inertie (momentum) et taux d'apprentissage variable
Descente des gradients conjugués	
Descente des gradients conjugués avec la méthode de mise à jour de Fletcher-Reeves (**traincgf**)	Il possède la plus petite mémoire de stockage parmi les algorithmes de gradient conjugués.
Descente des gradients conjugués avec la méthode de mise à jour de Polak-Ribiére (**traincgp)**	Nécessite une mémoire de stockage légèrement plus grande que traincgf. Convergence plus rapide sur quelques problèmes
Descente des gradients conjugués avec la méthode de reprises Powell-Beale (**traincgb**)	Nécessite une mémoire de stockage légèrement plus grande que traincgp. Convergence Généralement plus rapide.
Scaled conjugate gradient (**trainscg**)	Le seul algorithme de gradients conjugués qui n'exige aucune recherche de ligne. Très bon algorithme d'apprentissage en général
Quasi-Newton	

BFGS quasi-Newton (**trainbfg**)	Il exige le stockage d'une approximation de la matrice Hessiènne et nécessite plus de calcul à chaque itération que les algorithmes de gradients conjugués, mais possède habituellement une convergence plus rapide.
Sécante à un pas (**trainoss**)	Cet algorithme exige moins de stockage et calcul par époque que l'algorithme BFGS. On peut considérer cela un compromis entre des algorithmes de quasi-Newton complets et des algorithmes de gradients conjugués.
Levenberg-Marquard	
Levenberg-Marquardt (**trainlm**)	C'est l'algorithme d'apprentissage le plus rapide pour les réseaux de taille modérée. Il a la caractéristique de réduction de mémoire pour l'utilisation quand l'échantillon d'apprentissage est grand.
Régularisation	
Régularisation Bayésienne (**trainbr**)	Mise à jour des poids et des biais selon l'optimisation de Levenberg-Marquardt. Il réduit au minimum une combinaison d'erreurs quadratiques et des poids et détermine ensuite la combinaison correcte afin de produire un réseau avec une capacité de généralisation meilleure. Ce processus est appelé la régularisation bayésienne. Il réduit la difficulté de déterminer l'architecture de réseau optimum.

II.5.5. Evaluation des performances du réseau de neurones

Enfin, la dernière étape doit permettre d'estimer la qualité du réseau obtenu en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage. Elle permet à la fois d'apprécier les performances du système neuronal et de détecter le type de données qui posent problème. Si les performances ne sont pas satisfaisantes, il faudra, soit modifié l'architecture du réseau, soit modifié la base d'apprentissage (Khaouane 2013).

II.5.5. Limites

Les RNA possèdent quelques limites à savoir :

- Les RNA restent encore, en partie, une boite noire car ils ne permettent pas d'expliquer les relations pertinentes entre les variables. De ce point de vue, le système n'a donc qu'un pouvoir explicatif médiocre et n'est pas capable de retracer le cheminement suivi pour atteindre le résultat.
- Les modèles les plus simples sont souvent les meilleurs et les moins coûteux en temps de calcul, donc les RNA pourraient être utiles lorsque les modèles simples produisent des résultats insatisfaisants ce qui est généralement le cas des modèles économiques.
- Les RNA sont utilisés comme des outils de modélisation par apprentissage, qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points ; comme toute méthode qui s'appuie sur des techniques statistiques, l'utilisation des RNA nécessite que l'on dispose de données suffisamment représentatives.

Ces limites ne constituent pas pour autant un grand handicap pour les RNA dont les applications en différentes procédés continuent de faire surface (Azizi 2011).

II.6. Conclusion

Tout au long de ce chapitre, nous avons donné un maximum d'informations sur les réseaux de neurones d'une façon générale tout en mettant l'accent sur les réseaux de neurones de type feedforward, vraisemblablement les plus utilisés dans les modélisations statiques du fait qu'ils sont doués de la propriété d'approximation universelle.

Nous avons présenté un algorithme d'apprentissage très utilisé dans la communauté connexionniste : l'algorithme de rétro propagation du gradient. Plusieurs travaux lui ont été consacrés et un certain nombre de modifications ont été proposées pour accélérer le temps d'apprentissage, réduire les besoins en mémoire de stockage et améliorer la capacité de généralisation ainsi que les performances du réseau obtenu. Un résumé des caractéristiques des algorithmes d'apprentissage de rétro propagation implantée dans MATLAB® a été présenté.

Chapitre III. Modélisation du vieillissement membranaire

III.1. Introduction

Les réseaux de neurones artificiels (RN) ont acquis une grande popularité dans la dernière décennie en raison de leur parallélisme élevé, de leur robustesse de leur capacité inhérente à extraire à partir des données expérimentales, les relations fortement non-linéaires et complexes entre les variables du problème sans aucune connaissance détaillée du système (Si-Moussa 2010).

Ce chapitre porte sur la modélisation du vieillissement, il est divisé en six parties distinctes : la première partie présente la collecte des données, prétraitement et analyse, la deuxième partie sera consacrée au développement des modèles neuronaux, nous discuterons les performances des modèles neuronaux dans la troisième partie, les expressions mathématiques de modèle neuronal optimal seront abordées dans la quatrième partie, nous traiterons dans la cinquième partie l'analyse de sensibilité par la méthode de poids et dans la dernière partie nous discuterons le diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimise.

III.2. Collecte des données, prétraitement et analyse

Dans cette étude, nous avons utilisé les données disponibles dans la littérature (Axel 2011 et Ravereau-Delattre 2015). La taille de la base de données est montrée dans le tableau III.1.

Tableau III.1. Taille de la base de données et le nombre de composés organiques utilisés dans ce travail.

Base de données (BD)	Taille de base de données
BD1 avec perméabilité de l'eau "Aw"	304 points
BD2 avec perméabilité de soluté "As"	169 points
BD3 avec allongement à la rupture"ε_r"	166 points

Le choix des variables d'entrées et de sortie a été basé sur les conclusions de travail de Axel 2011 et Raverequ-Delattre 2015. Leurs études montrent que les cycles de nettoyage de membranes, lorsque réalisés dans des conditions sévères de pH et température, hors des limites recommandées par le fabricant, peuvent engendrer des transformations irréversibles de propriétés de la couche active et affecter sa sélectivité, par vieillissement chimique. Le vieillissement chimique par chloration est commenté par la pression appliquée, le temps de filtration, la dose "HOCl", pH et la température, hors des limites recommandées par le fabricant, peuvent engendrer

des transformations irréversibles de propriétés de la couche active et affecter sa sélectivité, par vieillissement chimique. Le vieillissement chimique de membrane par chloration est commenté par la pression appliquée, le temps de filtration, la dose "HOCl", pH et température. Les entrées considérées dans cette étude qui sont influencées sur la perméabilité de l'eau "Aw", la perméabilité de soluté "As" et sur l'allongement à la rupture membranaire "ε_r" sont : la durée de filtration, le pH, la pression, la dose de HOCL, molarité de soluté d'alimentation "M", la masse molaire de soluté d'alimentation "Ms".

Le nombre total de variables a été réduit en utilisant des matrices de corrélation (tableau III.1, tableau III.2 et tableau III.4). Chaque matrice regroupe l'intensité de la liaison qui existe entre ces paramètres. Cette intensité de liaison a été obtenue par le calcul des coefficients de corrélation de Pearson (r) (Équation III.1) (Benmerak et Zahraoui 2022) :

$$r(Z,Y) = \frac{\sum_i (z_i - \bar{z})\,(y_{i-}\bar{y})}{\sqrt{\sum_i (z_i - \bar{z})^2}\sqrt{\sum_i (y_{i-}\bar{y})^2}} \qquad \text{(III. 1)}$$

Où *zi* est la i^{ème} valeur du vecteur *Z* (la durée de filtration, le pH, la pression, la dose de HOCL, molarité de soluté d'alimentation "M", la masse molaire de soluté d'alimentation "Ms", la perméabilité de l'eau "Aw", la perméabilité de soluté "As" et l'allongement à la rupture membranaire "ε_r").

yi est la i^{ème} valeur du vecteur *Y* (la durée de filtration, le pH, la pression, la dose de HOCL, molarité de soluté d'alimentation "M", la masse molaire de soluté d'alimentation "Ms", la perméabilité de l'eau "Aw", la perméabilité de soluté "As" et l'allongement à la rupture membranaire "ε_r"), $\bar{z}$ et $\bar{y}$ sont respectivement les moyennes arithmétiques des vecteurs *Z* et *Y*. Le degré de coefficient de corrélation de Pearson doit être modéré (r < 0.75) (Benmerak et Zahraoui 2022).

Tableau III.2. Matrice des coefficients de corrélation pour la première base de données (BD1).

	Durée de filtration	**pH**	**Pression**	**Dose de HOCL**	**M**	**Ms**	**Aw**
Durée de filtration	1.0000	0.2491	0.0724	-0.1282	0.2030	-0.0849	0.1220
pH	0.2491	1.0000	-0.2333	-0.6397	-0.1200	-0.0381	0.3827
Pression	0.0724	-0.2333	1.0000	0.1661	0.1433	-0.0582	-0.0519
Dose de HOCL	-0.1282	-0.6397	0.1661	1.0000	0.2117	-0.0749	-0.4295
M	0.2030	-0.1200	0.1433	0.2117	1.0000	-0.4295	0.1430
Ms	-0.0849	-0.0381	-0.0582	-0.0749	-0.4295	1.0000	-0.2563
Aw	0.1220	0.3827	-0.0519	-0.4295	0.1430	-0.2563	1.0000

Tableau III.3. Matrice des coefficients de corrélation pour la deuxième base de données (BD2).

	Durée de filtration	**pH**	**Pression**	**Dose de HOCL**	**M**	**Ms**	**As**
Durée de filtration	1.0000	-0.5757	0.4193	0.5084	*-0.2166*	-0.2250	-0.4085
pH	-0.5757	1.0000	0.2686	-0.1045	-0.1453	-0.2144	-0.1597
Pression	0.4193	0.2686	1.0000	0.1072	-0.3281	0.1111	-0.7592
Dose de HOCL	0.5084	-0.1045	0.1072	1.0000	-0.1121	-0.0972	-0.2669
M	-0.2166	-0.1453	-0.3281	-0.1121	1.0000	-0.2760	0.5833
Ms	0.2250	-0.2144	0.1111	-0.0972	-0.2760	1.0000	-0.1896
As	-0.4085	-0.1597	-0.7592	-0.2669	0.5833	-0.1896	1.0000

Tableau III.4. Matrice des coefficients de corrélation pour la deuxième base de données (BD3).

	Durée de filtration	**pH**	**Ms**	**Dose de soluté**	**Allongement à la rupture**
Durée d'exposition	1	0.1153	0.1728	0.1097	-0.4064
pH	0.1153	1	0.3688	-0.1090	-0.1999
Ms	0.1728	0.36882	1	0.4689	-0.3207
Dose de soluté	0.1097	-0.1090	0.4689	1	-0.2999
Allongement à la rupture	-0.4064	-0.1999	-0.3207	-0.2999	1

Pour chaque base de données (BD1. BD2. BD3) un modèle réseau de neurones a été élaboré et un ensemble de variables d'entrées et de sortie a été identifié (Tableau III.5)

Tableau III.5. Entrées et sortie utilisées pour le développement des modèles neuronaux (RNA1. RNA2. RNA3).

	RNA1	**RNA2**	**RNA3**
Entrées	-Durée de filtration -pH -Pression -Dose de HOCL -Molarité (M) -Masse molaire de soluté (Ms)	-Durée de filtration -pH -Pression -Dose de HOCL -Molarité (M) -Masse molaire de soluté (Ms)	-Durée de filtration -pH -Molarité (M) -Masse molaire de soluté (Ms)
Sortie	Perméabilité de l'eau "Aw"	Perméabilité de soluté "As"	Allongement à la rupture "ε_r"

L'analyse statistique des données d'entrées et de sortie, en termes du minimum "min", de la moyenne arithmétique (Équation III.2) "$\bar{x}$", du maximum "max" et de la déviation standard (écart type) "DS" (Équation III.3) (Benmerak et Zahraoui 2022), sont présentées dans les tableaux III.6, III.7 et III.8.

$$\bar{x} = \frac{1}{n}\sum_{i=1}^{n} x_i \qquad \text{(III.2)}$$

$$DS = \left(\frac{1}{n}\sum_{i=1}^{n}(x_i - \bar{x})^2\right)^{1/2} \qquad \text{(III.3)}$$

Tableau III.6. Analyse statistique des données d'entrée et de sortie (BD1).

	Durée de filtration (Heure)	**pH**	**Pression (bar)**	**Dose HOCl (ppm.h)**	**Molarité (mol/l)**	**Ms (g/mol)**	**Aw ($L/h.m^2$.bar)**
Minimum	0.0000	6.9000	16.9295	0.0000	0.0100	42.3900	0.4581
Moyenne	24.5685	6.9638	58.4841	650.0000	0.4562	63.1619	1.3686
Maximum	221.3125	7.0000	63.2727	4000.0000	0.5500	150.1300	2.1047
DS	57.5793	0.0481	6.7257	1351.542	0.1807	22.0556	0.2831

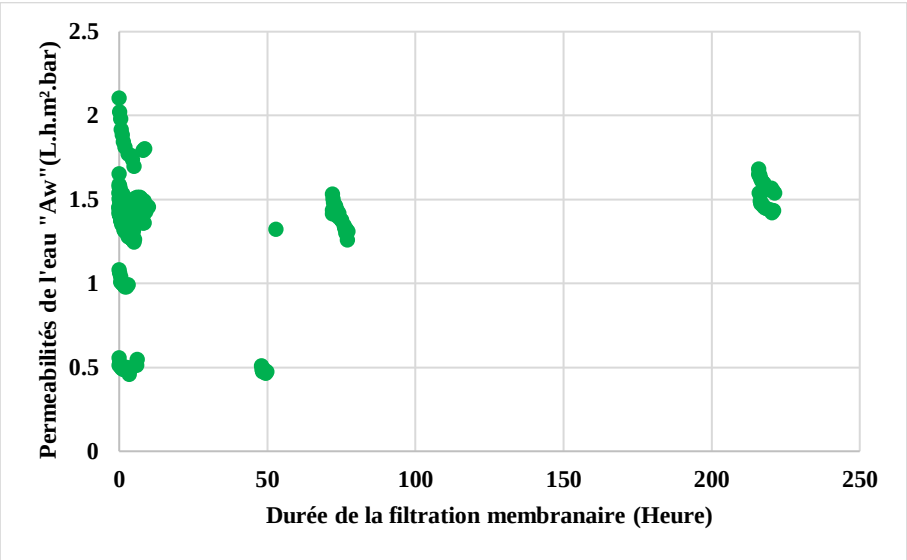
Tableau III.7. Analyse statistique des données d'entrée et de sortie (BD2).

	Durée de filtration (Heure)	**pH**	**Pression (bar)**	**Dose HOCl (ppm.h)**	**Molarité (mol/l)**	**Ms (g/mol)**	**As (m/h)**
Minimum	2082.51	6.9000	16.0181	0.0000	0.0100	42.3900	1.2400e-07
Moyenne	50492.266	6.9650	42.9393	1033.1360	0.3723	63.8028	0.76468
Maximum	91240.0194	7.0000	60.0000	4000.0000	0.5500	150.1300	1.93717
DS	24075.600	0.04781	19.1756	1625.8595	0.2257	24.2245	0.6525

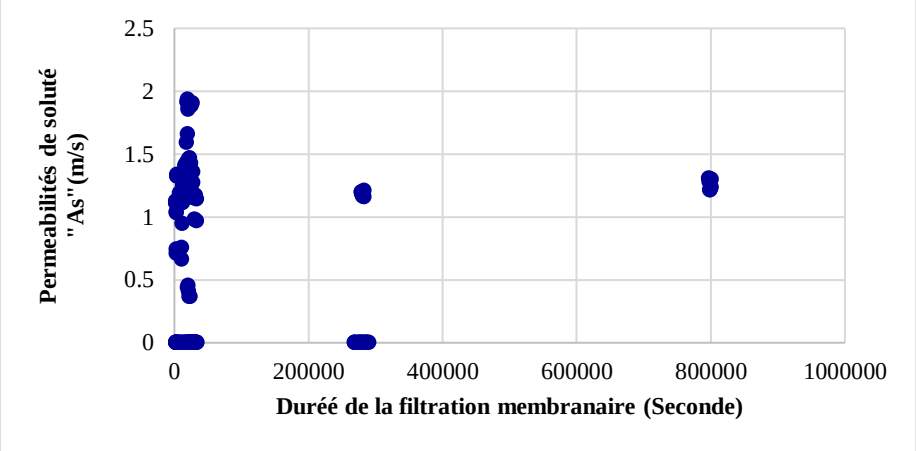
Tableau III.8. Analyse statistique des données d'entrée et de sortie (BD3).

	Durée de filtration [jours]	pH	Ms (g/mol)	Dose de soluté (ppm)	Allongement à la rupture [%]
Minimum	0.0000	2.0000	18.0000	1000.0000	0.0000
Moyenne	51.1004	6.9879	48.7530	3168.6747	78.0869
Maximum	135.174	11.5000	58.4400	4000.0000	100.0000
DS	42.8074	2.9170	15.1128	1346.7742	29.4124

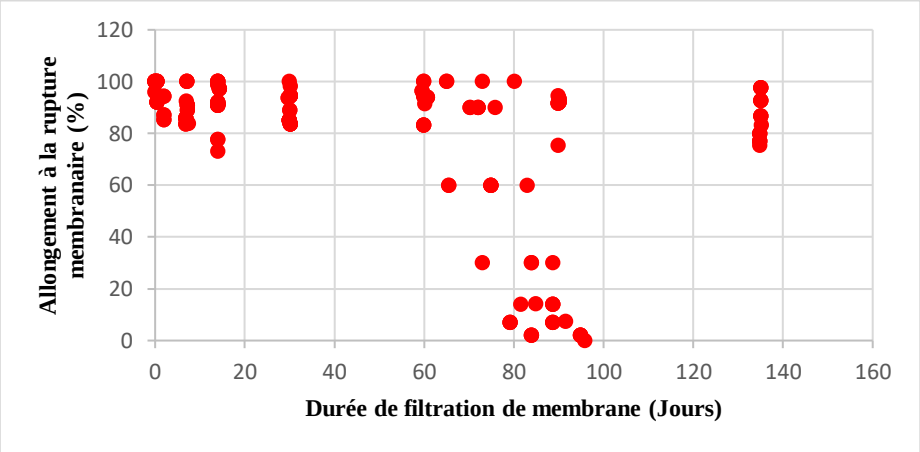
La figure III.1 représente la perméabilité de l'eau, perméabilité de soluté et l'allongement à la rupture membranaire en fonction de la durée de filtration membranaire pour les trois bases de données. La perméabilité de l'eau expérimentale en fonction de la durée de filtration membranaire est indiquée par des cercles verts pour BD1 "304 points", la perméabilité de soluté expérimental en fonction de la durée de filtration membranaire est indiquée par des cercles mauves pour BD2 "169 points". L'allongement à la rupture en fonction de la durée d'exposition est indiqué par des cercles rouges pour BD3 "166 points".



(a)



(b)



(c)

Figure III.1. Sorties expérimentales en fonction de la durée de filtration membranaire : (a) BD1, (b) BD2 et (c) BD3.

III.3. Développement des modèles RN

Cette étape concerne la création des modèles réseaux de neurones artificiels avec perméabilité de l'eau et soluté et l'allongement à la rupture"RNA_1 avec Aw, RN_2 avec As et RN_3 avec "ε_r".

Les réseaux de neurones artificiels (RN) sont particulièrement bien adaptés en raison de leur capacité à extraire des informations non-linéaires présentes dans la matrice de données (Yangjeh et Jenagharad 2009). Pour trouver un modèle non linéaire de vieillissement membranaire, l'utilisation de la méthode RN est nécessaire et est devenue une technique de modélisation

importante. Elle est largement utilisée pour les études non linéaires et est un outil puissant pour construire des modèles prédictifs.

Dans ce travail, une procédure basée sur le développement et l'optimisation de l'architecture d'un RN est décrite. Elle est basée, comme décrite sur l'organigramme ci-dessous

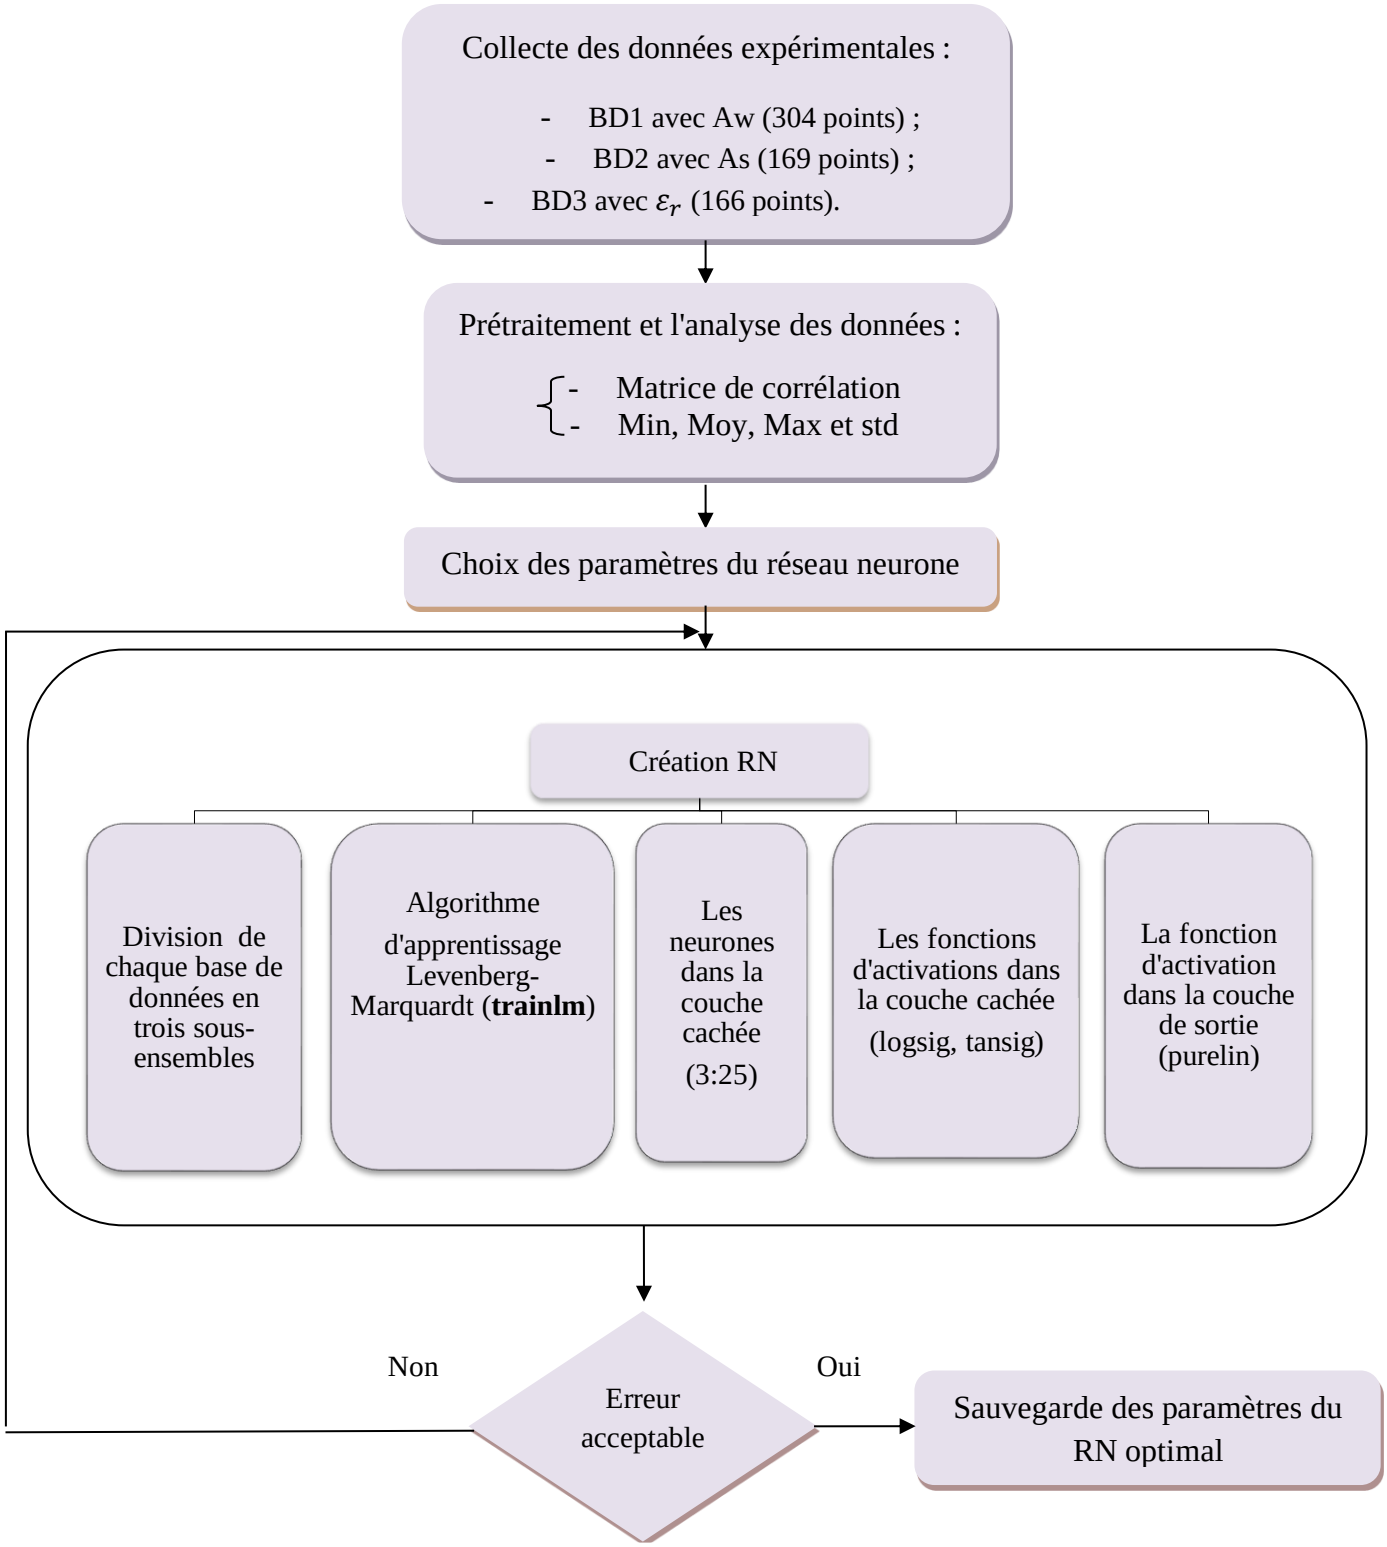


Figure III.2. Organigramme de développement et l'optimisation de l'architecture d'un RN.

L'algorithme d'apprentissage utilisé dans ce travail est le Levenberg-Marquardt (**trainlm**). Chaque RN contient trois couches de neurones ou des nœuds : une couche d'entrée, une couche cachée avec un nombre de neurones actifs optimisés lors de l'apprentissage et une couche de sortie avec une unité générant la valeur estimée de la perméabilité (RN1 et RN2) et l'allongement à la rupture membranaire (RN3). Le nombre de neurones dans la couche cachée a été varié de 3 à 25 neurones. Les fonctions d'activations « La tangente hyperbolique sigmoïde (tansig) et la sigmoïde logarithmique (logsig- » ont été utilisées dans la couche cachée. La fonction de transfert linéaire (purelin) a été utilisée dans la couche de sortie.

La procédure d'élaboration du RN décrite ci-dessus a été réalisée en utilisant MATLAB. Ce logiciel est utilisé pour optimiser l'architecture de deux modèles neuronaux (RN1, RN2) employés pour la perméabilité de l'eau et soluté de membranaire vieille et un modèle neurone (RN3) employé pour l'allongement à la rupture de membranaire.

III.4 Performance des modèles neuronaux

Les résultats de performances de trois modèles neuronaux "RN1 et RN2, RN3" en termes du coefficient de corrélation (R) pour les deux fonctions d'activation "tansig et logsig" sont résumés dans les tableaux III.9. Les résultats montrent que le premier modèle neuronal avec 24 neurones cachés et la fonction d'activation tangente hyperbolique sigmoïde "tansig" donne des meilleur résultats (R=0.9313 pour la phase de l'apprentissage, R=0.8873 pour la phase validation, R=0.9845 pour la phase de test et R=0.9335 pour la phase totale). Ceci implique qu'il model neuronal optimal ($RN1_{optimal}$) pour décrire la perméabilité de l'eau. Les résultats montrent que le deuxième modèle neuronal avec 4 neurones cachés et la fonction d'activation sigmoïde logarithmique "logsig" donne des meilleur résultats (R=0.9484 pour la phase de l'apprentissage, R=0.9710 pour la phase validation, R=0.9968 pour la phase de test et R=0.9569 pour la phase totale). Ceci implique qu'il model neuronal optimal ($RN2_{optimal}$) pour décrire la perméabilité de soluté. Les résultats montrent que le troisième modèle neuronal avec 7 neurones cachés et la fonction d'activation sigmoïde logarithmique "logsig" donne des meilleur résultats (R=0.7801 pour la phase de l'apprentissage, R=0.8993 pour la phase validation, R=0.9920 pour la phase de test et R=0.8353 pour la phase totale). Ceci implique qu'il model neuronal optimal ($RN3_{optimal}$) pour décrire l'allongement de la rupture membranaire.

Tableau III.9. Effet de nombre de neurones et les fonctions d'activation dans la couche cachée.

		3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
	RNA1 (logsig)																							
RNA avec perméabilité de l' eau (A_W)	$R_{Apprentissage}$	0.74	0.76	0.85	0.88	0.76	0.93	0.80	0.74	0.94	0.93	0.71	0.73	0.73	0.92	0.69	0.91	0.80	0.78	0.91	0.85	0.87	0.91	0.91
	$R_{validation}$	0.80	0.86	0.77	0.86	0.77	0.79	0.81	0.82	0.92	0.82	0.96	0.77	0.79	0.92	0.91	0.88	0.89	0.95	0.86	0.92	0.87	0.86	0.93
	R_{test}	0.82	0.95	0.95	0.96	0.91	0.97	0.87	0.91	0.97	0.97	0.96	0.87	0.91	0.95	0.91	0.96	0.92	0.98	0.94	0.96	0.94	0.98	0.97
	R_{total}	0.75	0.81	0.86	0.89	0.78	0.91	0.80	0.77	0.94	0.92	0.77	0.76	0.76	0.92	0.77	0.91	0.84	0.82	0.91	0.89	0.88	0.93	0.92
	RNA1 (tansig)																							
	$R_{Apprentissage}$	0.85	0.76	0.71	0.74	0.90	0.75	0.67	0.94	0.70	0.91	0.90	0.75	0.81	0.77	0.90	0.71	0.79	0.88	0.80	0.84	0.79	0.93	0.93
	$R_{validation}$	0.93	0.78	0.92	0.82	0.95	0.86	0.97	0.85	0.84	0.95	0.90	0.75	0.75	0.75	0.92	0.92	0.73	0.92	0.96	0.96	0.93	0.88	0.97
	R_{test}	0.72	0.85	0.74	0.78	0.92	0.76	0.96	0.75	0.82	0.85	0.98	0.79	0.85	0.88	0.87	0.90	0.76	0.95	0.94	0.97	0.71	0.98	0.97
	R_{total}	0.84	0.77	0.75	0.76	0.90	0.76	0.75	0.83	0.74	0.91	0.91	0.75	0.80	0.79	0.90	0.76	0.77	0.90	0.84	0.88	0.79	0.93	0.94
	RNA2(logsig)																							
RNA2 avec perméabilité de soluté (A_s)	$R_{Apprentissage}$	0.94	0.94	0.94	0.95	0.94	0.95	0.95	0.95	0.95	0.95	0.94	0.95	0.94	0.95	0.94	0.95	0.95	0.93	0.95	0.93	0.95	0.95	0.96
	$R_{validation}$	0.83	0.97	0.95	0.94	0.98	0.93	0.92	0.94	0.97	0.93	0.93	0.97	0.96	0.96	0.98	0.96	0.96	0.98	0.88	0.92	0.97	0.95	0.95
	R_{test}	0.98	0.99	0.99	0.98	0.98	0.97	0.98	0.98	0.98	0.98	0.99	0.98	0.98	0.98	0.98	0.97	0.97	0.99	0.99	0.99	0.96	0.97	0.98
	R_{total}	0.93	0.95	0.95	0.95	0.95	0.95	0.95	0.95	0.96	0.95	0.94	0.96	0.95	0.96	0.95	0.95	0.95	0.95	0.95	0.94	0.95	0.95	0.96
	RNA2(tansig)																							
	$R_{Apprentissage}$	0.76	0.76	0.77	0.80	0.77	0.77	0.75	0.85	0.75	0.74	0.74	0.75	0.75	0.76	0.75	0.76	0.75	0.75	0.77	0.77	0.79	0.74	0.74
	$R_{validation}$	0.95	0.95	0.96	0.86	0.89	0.98	0.94	0.67	0.97	0.95	0.99	0.96	0.99	0.94	0.99	0.94	0.96	0.96	0.96	0.93	0.93	0.95	0.93
	R_{test}	0.98	0.95	0.96	0.92	0.96	0.99	0.99	0.96	0.96	0.99	0.99	0.98	0.98	0.99	0.98	0.98	0.99	0.99	0.99	0.98	0.99	0.99	0.97
	R_{total}	0.95	0.93	0.96	0.81	0.83	0.96	0.95	0.82	0.95	0.95	0.96	0.96	0.96	0.96	0.96	0.96	0.96	0.96	0.96	0.96	0.95	0.95	0.96
	RNA3 (logsig)																							
RNA3 avec allongement à la rupture (ε_r)	$R_{Apprentissage}$	0.80	0.87	0.80	0.77	0.78	0.79	0.81	0.79	0.77	0.82	0.80	0.79	0.72	0.78	0.83	0.75	0.84	0.77	0.78	0.84	0.79	0.71	0.76
	$R_{validation}$	0.86	0.55	0.81	0.82	0.89	0.78	0.95	0.85	0.89	0.76	0.96	0.85	0.92	0.83	0.60	0.95	0.90	0.93	0.94	0.84	0.74	0.89	0.93
	R_{test}	0.92	0.97	0.97	0.96	0.99	0.97	0.97	0.94	0.98	0.96	0.92	0.94	0.94	0.95	0.95	0.96	0.96	0.92	0.94	0.94	0.98	0.92	0.96
	R_{total}	0.83	0.81	0.82	0.81	0.83	0.81	0.84	0.81	0.81	0.83	0.83	0.82	0.78	0.81	0.82	0.81	0.87	0.81	0.82	0.85	0.82	0.75	0.82
	RNA3 (tansig)																							
	$R_{Apprentissage}$	0.55	0.55	0.62	0.70	0.55	0.59	0.57	0.57	0.65	0.60	0.65	0.60	0.55	0.56	0.65	0.58	0.58	0.63	0.61	0.62	0.55	0.55	0.56
	$R_{validation}$	0.82	0.82	0.80	0.80	0.81	0.81	0.72	0.82	0.83	0.88	0.83	0.78	0.80	0.80	0.81	0.71	0.82	0.82	0.81	0.72	0.75	0.75	0.81
	R_{test}	0.94	0.94	0.95	0.95	0.95	0.92	0.92	0.92	0.95	0.94	0.93	0.93	0.93	0.90	0.91	0.91	0.95	0.95	0.94	0.94	0.92	0.94	0.94
	R_{total}	0.55	0.55	0.55	0.56	0.56	0.56	0.58	0.58	0.55	0.55	0.54	0.54	0.57	0.57	0.57	0.52	0.52	0.56	0.56	0.56	0.56	0.57	0.57

Le tableau III.10 montre la structure de modèles neuronaux optimaux $RN_{optimaux}$.

Tableau III.10. Structure des modèles $RN_{optimaux}$.

Modèles de RN	**Algorithme d'apprentissage**	**Couche entré**	**Couche cachée**		**Couche sortie**	
		Nombre de neurone	**Nombre de neurone**	**Fonction d'activation**	**Nombre de neurone**	**Fonction d'activation**
RN1	Levenberg Marquardt (trainlm)	6	24	Tanh	1	Purlein
RN2		6	4	Logsig	1	
RN3		4	7	Logsig	1	

Selon la discussion précédente, un modèle neuronal $RN_{optimal}$ a été développé dans le but de modélisation du vieillissement membranaire. L'intrigue et les paramètres de la régression linéaire sont franchement obtenus. Le pouvoir de prédiction d'un tel modèle peut être estimé par le coefficient de corrélation *R*, une valeur de *R* supérieure à 0.5 est généralement considérée comme satisfaisante, une valeur supérieure à 0.9 est excellente (Benmerak et Zahraoui 2022).

La figure III.3 montre les courbes de régression linéaire de la perméabilité de l'eau "A_w" calculée par le premier modèle neuronal "RN1" optimisé avec la perméabilité de l'eau "A_w" expérimentale avec des vecteurs de régression approchant de l'idéal ([α, β, R] = [0.8600, 0.1800, 0.93139] "phase d'apprentissage", [α, β, R] = [0.9200, 0.0780, 0.8873] "phase de validation", [α, β, R] = [0.9800, 0.0230, 0.9845] "phase de test", et [α, β, R] = [0.8800, 0.1500, 0.9335] "phase totale"). Les coefficients des corrélations sont généralement considérés comme excellentes ($0.90 \leq R \leq 1.00$) pour la phase d'apprentissage, la phase de test et la phase totale. Ce qui montre une bonne robustesse du premier modèle neuronal optimal "$RN1_{optimal}$" établi et la possibilité de la prédiction des différents paramètres qui caractérisent la perméabilité de l'eau "A_w" par membrane vieille.

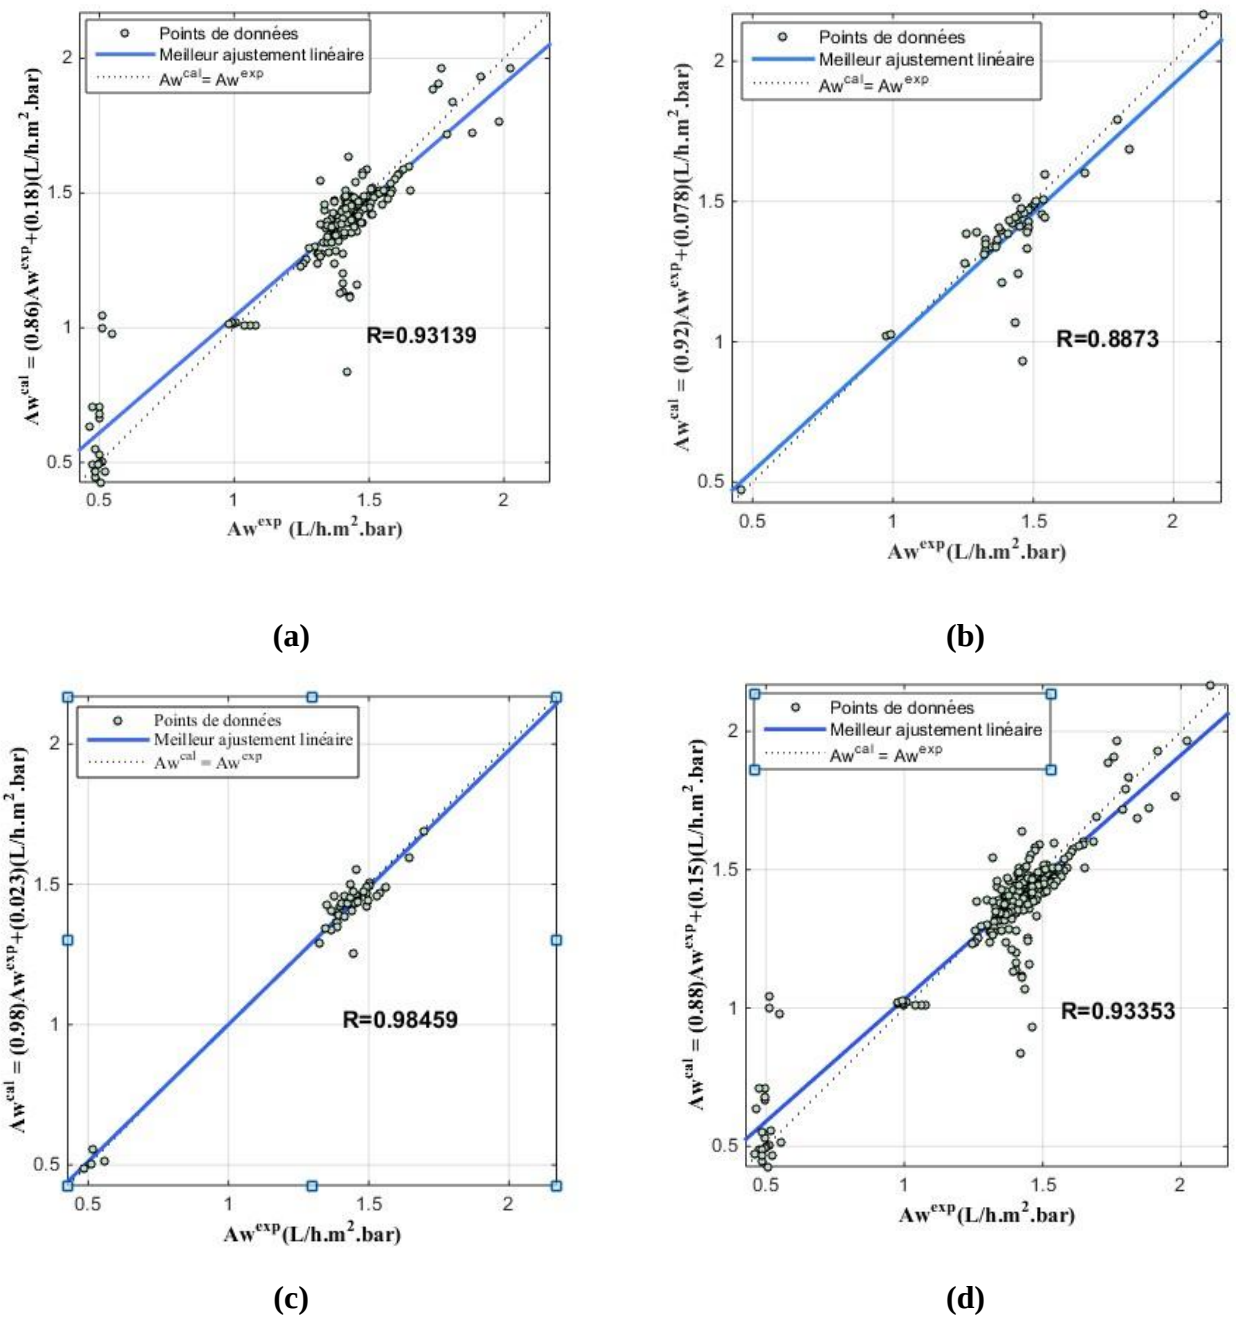


Figure III.3. Comparaison entre les valeurs expérimentales et les valeurs calculées pour RN1 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.

La figure III.4 montre les courbes de régression linéaire de la perméabilité de soluté "A_s" calculés par le deuxième modèle neuronal "RN2" optimisé avec les perméabilités de soluté "A_s" expérimentales avec des vecteurs de régression approchant de l'idéal ([α, β, R] = [0.9200, 0.0720, 0.9484] "phase d'apprentissage", [α, β, R] = [0.9100, 0.0730, 0.9710] "phase de validation", [α, β, R] = [0.9600, 0.0240, 0.9968] "phase de test" et [α, β, R] = [0.9211, 0.0653, 0.9596] "phase totale"). Les coefficients

des corrélations sont généralement considérés comme excellentes ($0.90 \leq R \leq 1.00$) pour la phase d'apprentissage, la phase de validation, la phase de test et la phase totale. Ce qui montre une bonne robustesse du deuxième modèle neuronal optimal "$RN2_{optimal}$" établi et la possibilité de la prédiction des différents paramètres qui caractérisent la perméabilité de soluté "A_s" par membrane vieille.

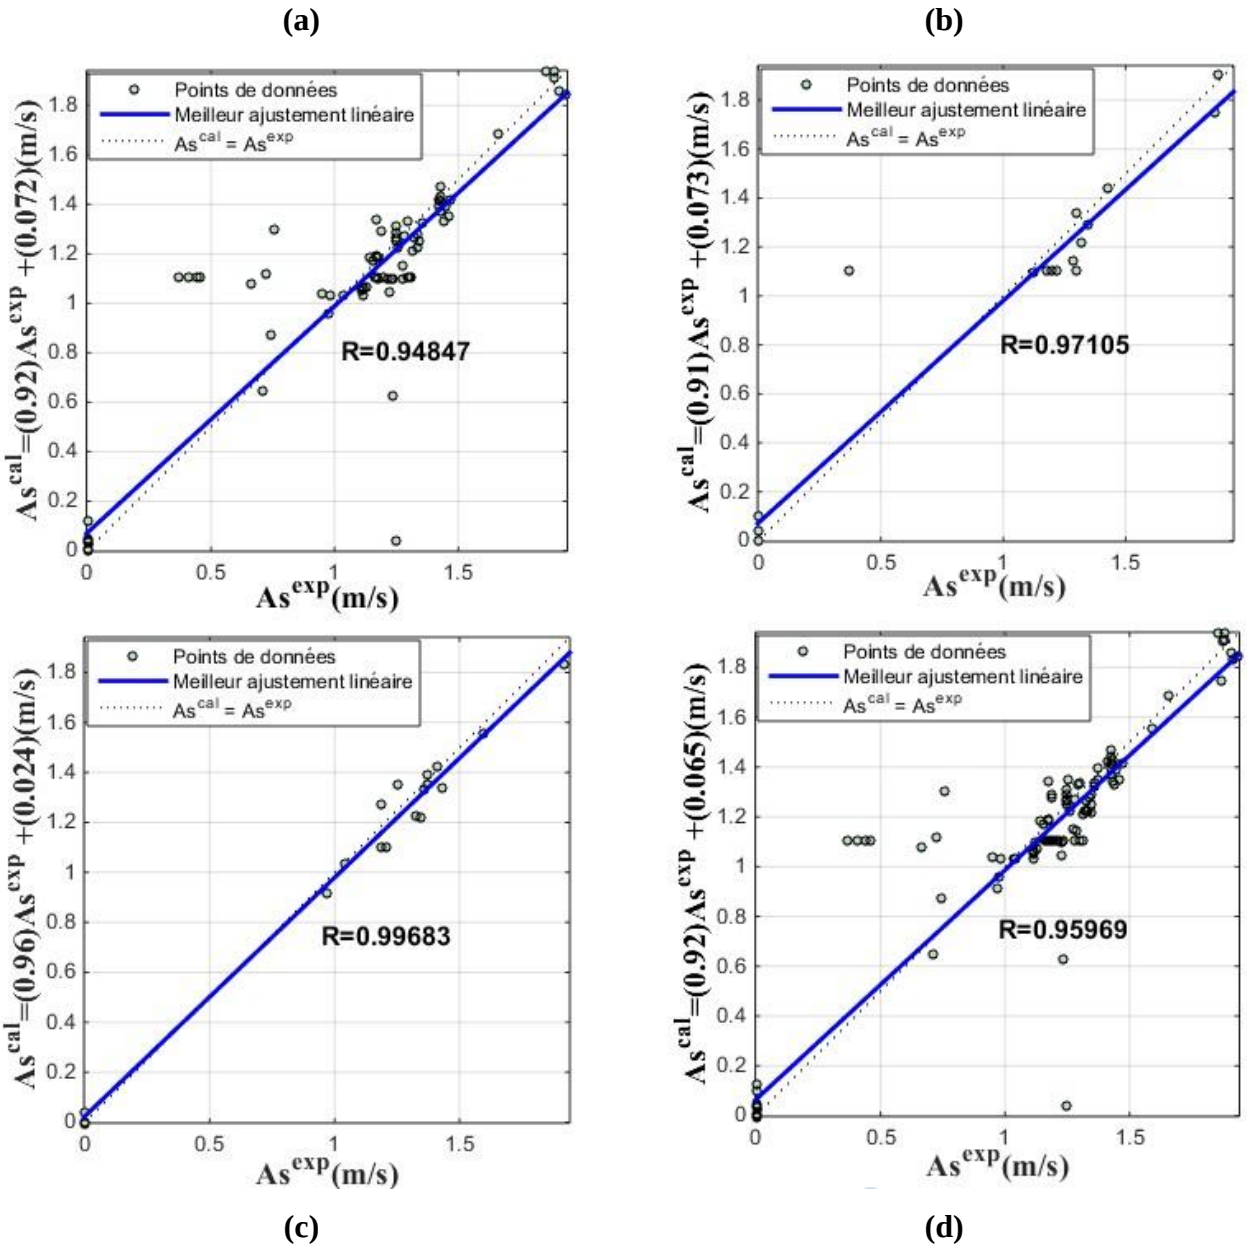


Figure III.4. Comparaison entre les valeurs expérimentales et les valeurs calculées pour RN2 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.

La figure III.5 montre les courbes de régression linéaire de l'allongement à la rupture membranaire "ε_r" calculée par le troisième modèle neuronal "$RN3_{optimal}$" optimisé avec l'allongement à la rupture "ε_r" expérimentale avec des vecteurs de régression approchant de l'idéal ([α, β, R] = [0.6700,

26.0000, 0.7801] "phase d'apprentissage", [α, β, R] = [0.7200, 23.0000, 0.8993] "phase de validation", [α, β, R] = [0.8200, 17.0000, 0.9920] "phase de test" et [α, β, R] = [0.6979, 23.0000, 0.8353] "phase totale"). Les coefficients des corrélations sont généralement considérés comme excellentes ($0.90 \leq R \leq 1.00$) pour la phase d'apprentissage, la phase de test, la phase de validation et la phase totale. Ce qui montre une bonne robustesse du troisième modèle neuronal optimal "$RN1_{optimal}$" établi et la possibilité de la prédiction des différents paramètres qui caractérisent l'allongement à la rupture membranaire vieille "ε_r".

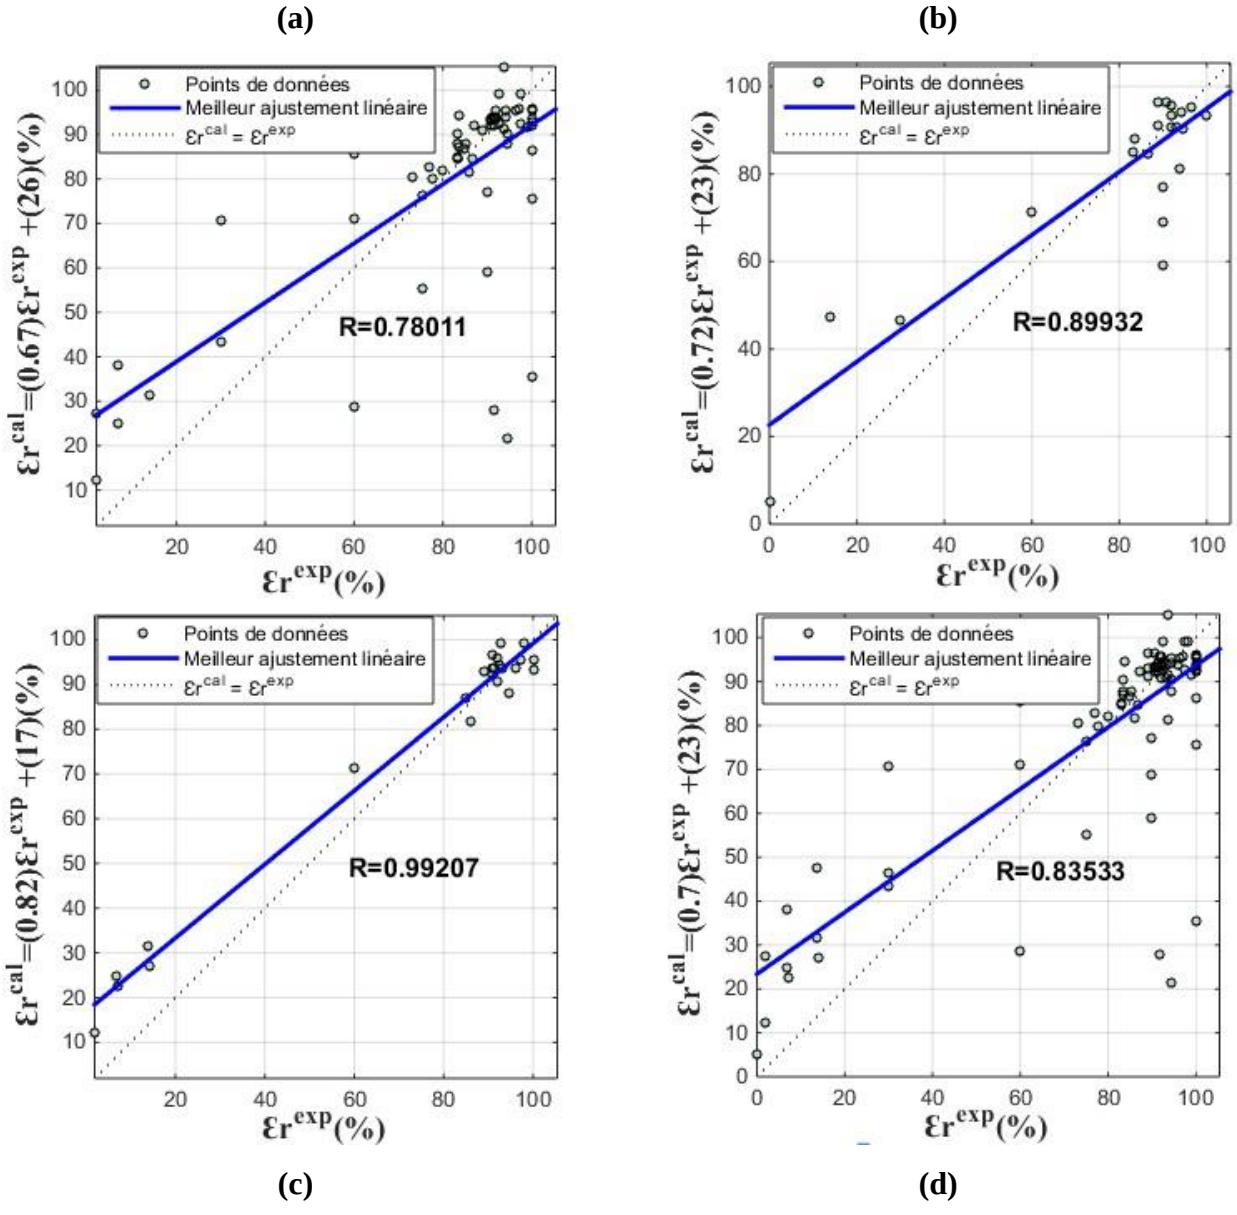


Figure III.5. Comparaison entre les valeurs expérimentales et les valeurs calculée s pour RN2 : (a) la phase d'apprentissage, (b) la phase de validation, (c) la phase de test et (d) la phase la phase totale.

La performance de chaque modèle neuronal optimal a été évaluée en termes de coefficient de corrélation (R), la racine de l'erreur quadratique moyenne (REQM), l'erreur absolue moyenne *(EAM*) et l'erreur de standard de prédiction (*ESP*). R, REQM, EAM et ESP ont été utilisées pour déterminer l'erreur de modélisation entre les valeurs expérimentales et calculées. La racine de l'erreur quadratique moyenne, l'erreur absolue moyenne et l'erreur de standard de prédiction sont définies comme suit (Benmerak et Zahraoui 2022) :

$$REQM = \sqrt{\frac{\sum_{i=1}^{n}(Y_{i,exp} - Y_{i,cal})^2}{n}} \quad \text{(III. 4)}$$

$$EAM = \frac{1}{n}\sum_{i=1}^{n}\left|(y_{i,exp} - y_{i,cal})\right| \quad \text{(III. 5)}$$

$$ESP(\%) = \frac{REQM}{Y_e} * 100 \quad \text{(III. 6)}$$

Où n est le nombre total de données,$y_{i,exp}$est la valeurexpérimentale,$y_{i,cal}$représente la valeur calculée à partir du modèle neuronal et Y_e est la valeur moyenne des données expérimentales.

Les vecteurs de régression linéaire pour les trois modèles neuronaux optimaux (RN1, RN2 et RN3) sont présentés dans le tableau III.12. Il est prouvé que les approches neuronales proposées donnent des résultats satisfaisants avec des valeurs de vecteur de régression approchant à l'idéal [équation linéaire : $y^{cal} = \alpha y^{exp} + \beta$, α=1 (pente), β=0 (ordonnée à l'origine), R=1 (coefficient de corrélation)] dans l'ajustement des profils des RN1, RN2 et RN3.

Tableau III.11. Vecteurs de régression linéaire issue de l'équation linéaire : [équation linéaire : $y^{cal} = \alpha y^{exp} + \beta$, α (pente), β(ordonnée à l'origine), R(coefficient de corrélation).

		α	β	R
RN1	**Phase d'apprentissage**	0.8600	0.1800	0.9313
	Phase de test	0.9800	0.0230	0.9845
	Phase de validation	0.9200	0.0780	0.8837
	Totale	0.8800	0.1500	0.9335
RN2	**Phase d'apprentissage**	0.9200	0.0720	0.9484
	Phase de test	0.9600	0.0240	0.9968
	Phase de validation	0.9100	0.0730	0.9710

	Totale	0.9211	0.0653	0.9596
RN3	**Phase d'apprentissage**	0.6700	26.0000	0.7801
	Phase de test	0.8200	17.0000	0.9920
	Phase de validation	0.7200	23.0000	0.8993
	Totale	0.7000	23.0000	0.8353

La figure III.6 représente la performance des modèles neuronaux optimaux pour la phase totale. Elle montre que les modèles (RN1, RN2 et RN3) ont donné des erreurs plus faibles. Ce qui indique que les modèles neuronaux optimaux possèdent une capacité de prédiction très élevée pour prédire la perméabilité de l'eau, la perméabilité du soluté et l'allongement à la rupture membranaire.

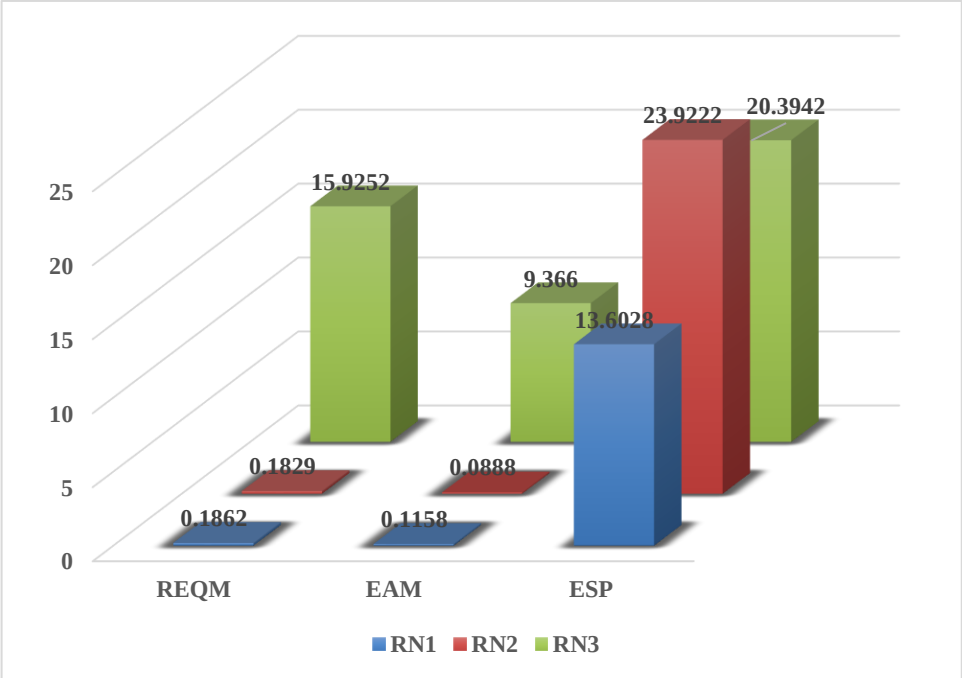


Figure III.6. Performances des modèles neuronaux optimaux (RN1, RN2 et RN3) pour la phase totale.

III.5 Expressions mathématiques des modèles neuronaux optimaux

À partir du RN optimisé, représenté sur la figure III.7, on peut exprimer l'assimilation de la perméabilité de l'eau, perméabilité de soluté et l'allongement à la rupture membranaire vieille par un modèle mathématique y incorporant toutes les entrées Ei (durée de filtration, pH, pression, température, molarité de soluté et masse molaire de soluté) pour RNA1 et RN2 et Ei (durée de filtration, pH, molarité de soluté, masse molaire de soluté) pour RNA3, comme suit :

Les sorties Zj de la couche cachée :

$$Z_j = f_H\left[\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right] = \frac{exp\left(\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right) - exp\left(-\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right)}{exp\left(\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right) + exp\left(-\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right)} \quad \text{(III. 7)}$$

j=1, 2, …,24

La sortie "perméabilité de l'eau" :

$$A_W(RN1) = f_0\left[\sum_{j=1}^{24} w_{1j}^H Z_j + b_1^o\right] = \sum_{j=1}^{24} w_{1j}^H Z_j + b_1^o \quad \text{(III. 8)}$$

La combinaison des équations (III.6) et (III.7) mène à la formule mathématique suivante qui décrit l'assimilation de rétention en prenant en compte toutes les entrées *Ei* (durée de filtration, pH, pression, température, molarité de soluté et masse molaire de soluté):

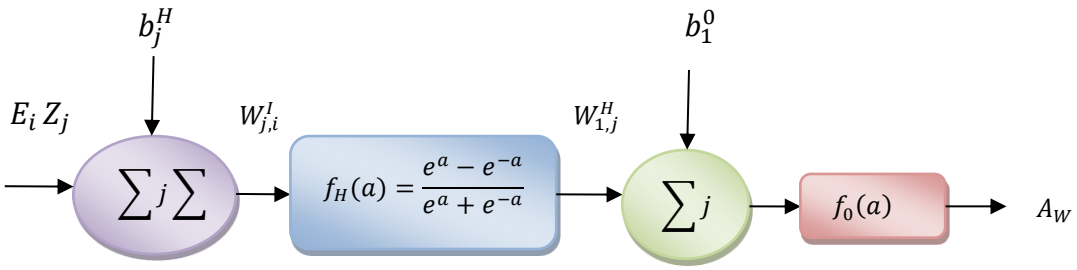
$$A_W(RN1) = \sum_{j=1}^{24} w_{1j}^H \frac{exp\left(\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right) - exp\left(-\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right)}{exp\left(\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right) + exp\left(-\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right)} + b_1^o \quad \text{(III. 9)}$$

De même, perméabilité de soluté (A_s) peut être exprimée par d'équation mathématiques extraite du RN2 optimisé comme suit :

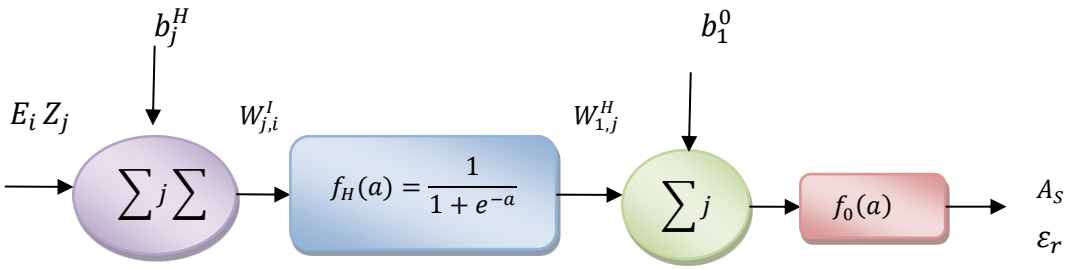
$$A_s(RN2) = \sum_{j=1}^{4} w_{1j}^H \frac{1}{1 + exp\left(-\sum_{i=1}^{6} w_{ji}^I E_i + b_j^H\right)} + b_1^o \quad \text{(III. 10)}$$

De même, l'allongement à la rupture membranaire veille (ε_r) peut être exprimée par d'équation mathématiques extraite du RN3 optimisé comme suit avec les entrées *Ei* (durée de filtration, pH, molarité de soluté, masse molaire de soluté) :

$$\varepsilon_r(RN3) = \sum_{j=1}^{7} w_{1j}^H \frac{1}{1 + exp\left(-\sum_{i=1}^{4} w_{ji}^I E_i + b_j^H\right)} + b_1^o \quad \text{(III. 11)}$$



(a)



(b)

Figure III.7. Représentation schématique des : (a) RN1, (b) RN2 et RN3 optimisés.

Ou w_{ji}^I représente le poids synaptique de la connexion du neurone *i* de la couche d'entrée au neurone *j* de la couche cachée (6 lignes x 24 colonnes pour RN1, 6 lignes x 4 colonnes pour RN2 et 4 lignes x 7 colonnes pour RN3); w_{1j}^H représente le poids synaptique de la connexion du neurone *j* de la couche cachée au neurone de la couche de sortie (24 lignes x 1 colonnes pour RN1, 4 lignes x 1 colonnes pour RN2 et 7 lignes x 1 colonnes pour RN3); b_j^H représente les biais du neurone *j* de la couche cachée (24 lignes x 1 colonnes pour RN1, 4 lignes x 1 colonnes pour RN2 et 7 lignes x 1 colonnes pour RN3) et b_1^o représente les biais du neurone *j* de la couche de sortie (1 ligne pour RN1, RN2 et RN3). Les matrices des poids et biais, des trois RN optimisés, sont donnés dans les tableaux III.12, III.13 et III.14.

Les équations mathématiques, dérivant des modèles neuronaux optimisés, contiennent juste le degré exigé de complexité et incluent dans leurs formules les caractéristiques pertinentes de la perméabilité de l'eau, perméabilité de soluté et l'allongement à rupture membranaire vieille à savoir les entrées. Ils peuvent donc facilement être appliqués dans des boucles de contrôle du processus de la perméabilité de l'eau, perméabilité de soluté et l'allongement à rupture membranaire vieille.

Tableau III.12. Poids et biais du RN1 optimal.

Connexions Couche entrée-Couche caché							Connexions Couche caché -Couche de sortie	
Poids						Biais	Poids	Biais
$W_{j.1}^{I}$	$W_{j.2}^{I}$	$W_{j.3}^{I}$	$W_{j.4}^{I}$	$W_{j.5}^{I}$	$W_{j.6}^{I}$	b_j^H	$W_{I.j}^{H}$	b_1^0
1.3838	1.3847	0.48458	0.4056	-0.1144	-1.644	-2.2954	-1.5556	
2.0965	0.5078	1.2050	-1.258	0.1864	2.2443	-1.636	-2.7423	
-1.1989	0.1370	-1.1849	1.1564	-1.5979	-1.0735	1.8824	-0.5826	
2.1827	-0.2119	1.1008	-0.9419	-0.5477	1.3951	-1.4675	-2.3166	
0.9429	0.8647	0.4129	-1.5158	-1.2118	0.58689	-1.2092	-1.5922	
-1.1411	-0.6798	-0.9610	-1.0339	0.8518	1.2494	1.33	0.6790	
-4.753	3.2308	-2.3756	1.7905	-0.3965	-1.2994	0.83196	-3.609	
1.4493	-2.3263	0.3844	-0.4419	-0.0157	-0.47858	-1.0344	-1.9317	
3.1752	-1.7445	2.6911	-1.6164	-1.2806	0.0366	-0.62477	2.4401	
2.1449	-4.5074	-4.0725	0.0792	0.81106	0.1114	-0.2044	5.2068	
-1.2817	-1.7507	0.0648	0.5523	-1.0862	-0.2329	0.0223	-0.9245	0.9572
2.9623	1.17847	-0.6184	-0.0455	0.7222	0.9809	-0.0726	-2.1141	
2.4226	0.3007	2.0879	2.0449	1.1832	-0.5199	0.3634	3.1672	
-3.1913	-0.8084	-9.0276	-1.0456	1.8715	-2.1106	1.3143	7.0704	
1.4183	1.9712	0.1622	0.3811	-0.4292	-1.1515	0.5183	0.2807	
-1.4444	-1.3763	2.6047	2.7528	-1.1957	-0.1517	-1.3724	-3.1876	
4.0735	0.7294	10.7166	0.6170	-2.2054	2.1308	-2.028	5.5173	
1.4477	-0.3868	1.9564	0.1264	2.0648	0.61962	0.8609	-1.1631	
2.1859	0.25196	2.2109	-2.1362	-2.4203	-0.1212	1.3089	-3.4254	
8.9649	0.5871	-2.0536	-1.4854	0.1939	-4.2005	6.9832	-5.2626	
-2.3171	-2.3187	-4.7824	1.3338	0.7520	0.8604	1.8236	-2.8799	
-3.3765	-1.0591	-0.8806	0.7995	0.8963	0.5509	-2.7786	-2.3435	
1.7258	-0.5361	1.0155	2.0626	-2.1031	-0.7105	2.4666	2.8668	
2.1654	0.70631	-1.1459	-2.1293	-0.2876	0.2709	2.6884	2.2144	

Tableau III.13. Poids et biais du RN2 optimal.

Connexions Couche entrée-Couche caché							Connexions Couche caché -Couche de sortie	
Poids						Biais	Poids	Biais
$W_{j.1}^{I}$	$W_{j.2}^{I}$	$W_{j.3}^{I}$	$W_{j.4}^{I}$	$W_{j.5}^{I}$	$W_{j.6}^{I}$	b_j^H	$W_{I.j}^{H}$	b_1^0
12.8609	8.1907	-5.323	3.1257	-9.5332	0.11367	-13.517	-1.1412	
-242.0826	-124.5045	117.6360	-25.1161	-47.0295	46.3104	10.7435	-1.1025	
2.5264	1.3381	-6.5824	0.42612	-0.2247	1.8271	-3.7142	1.2604	0.14262
-0.72203	5.637	-1.9942	6.0889	6.8319	-10.5660	-17.351	-1.1417	

Tableau III.14. Poids et biais du RN3 optimal.

Connexions Couche entrée-Couche caché					Connexions Couche caché -Couche de sortie	
Poids				Biais	Poids	Biais
$W_{j.1}^{I}$	$W_{j.2}^{I}$	$W_{j.3}^{I}$	$W_{j.4}^{I}$	b_j^H	$W_{1.j}^{H}$	b_1^0
1.0688	-1.991	-0.81644	-3.2885	-4.7146	-1.1409	
-1.8992	6.5734	2.6886	6.5955	-3.6795	3.4169	
0.16976	2.3253	4.9249	1.6749	-0.060329	-0.1941	
14.9934	5.2499	-18.4825	23.8975	3.291	6.4454	-12.3837
-10.5876	16.6579	0.22157	-7.8965	3.3084	3.1523	
11.1633	-11.2799	10.7741	-19.1483	10.5906	10.2035	
-25.8495	-10.07	0.68497	6.0607	-21.2806	6.4934	

L'architecture des réseaux de neurones optimaux obtenus est donnée sur la figure III.9, ci-après

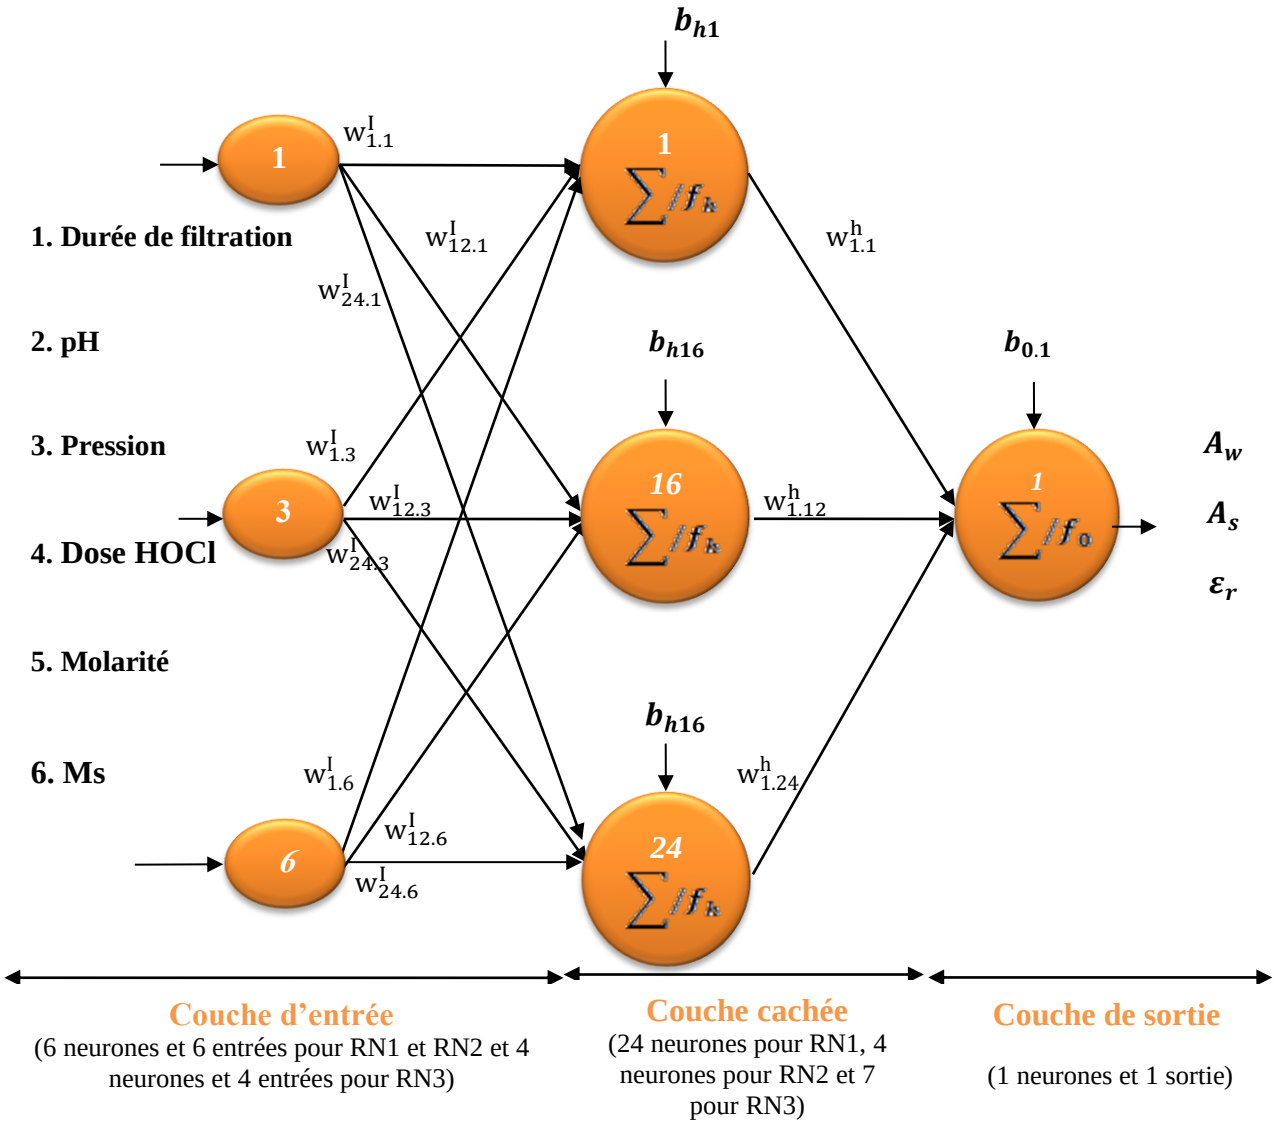


Figure III.8. Architecture finale des réseaux de neurones optimaux de type feedforward pour la prédiction de la perméabilité de l'eau, la perméabilité de soluté et l'allongement à rupture membranaire veille par membrane.

III.6. Analyse de sensibilité par la méthode de poids

Cette méthode, proposée d'abord par Garson (Garson 1991) et reprise par Goh (Goh 1995), donne une quantification de l'importance relative (*IR*) des différentes entrées sur la sortie du RN (Gevrey et al. 2003). Elle se base sur le partitionnement des poids de connexions en :

- Poids de connexions entrée-cachée (w_{ji}^{I}) ;
- Poids de connexions cachée-sortie (w_{1j}^{H}).

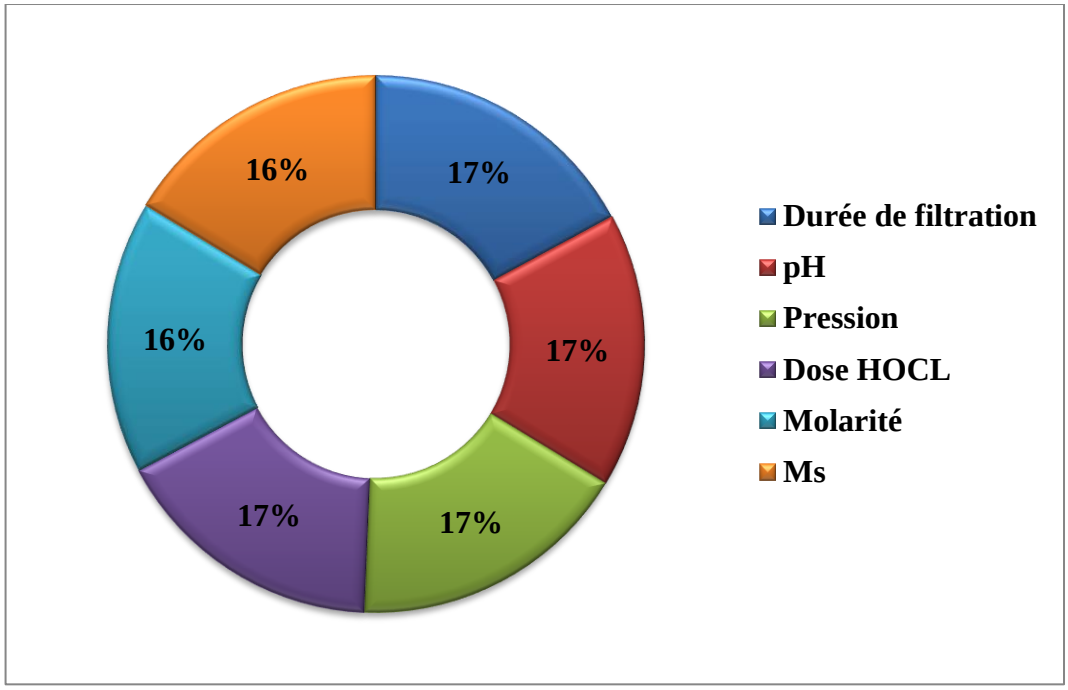
L'importance relative "IR" de chaque d'entrées sur la sortie est obtenu par les deux équations suivantes (Ammi et. 2021):

$$Q_{ji} = \frac{\left|w_{ji}^{I} w_{1j}^{H}\right|}{\sum_{i=1}^{ni}\left|w_{ji}^{I} w_{1j}^{H}\right|} \quad \text{(III. 13)}$$

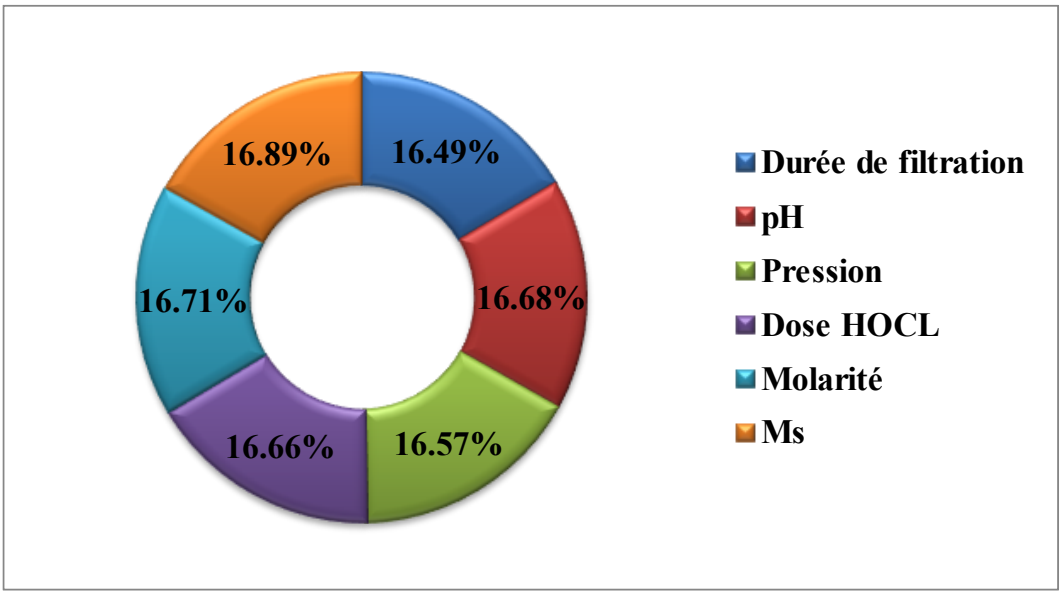
$$RI_{i}(\%) = \frac{\sum_{j=1}^{nj} Q_{ji}}{\sum_{i=1}^{ni}\sum_{j=1}^{nj} Q_{ji}} * 100 \quad \text{(III. 14)}$$

Pour voir la contribution ainsi que le profil de variation de chaque variable d'entrée (durée de filtration, ph, pression, température, molarité, masse molaire de soluté) sur la sortie de chaque réseau (perméabilité de l'eau "Aw", perméabilité de soluté "As" et allongement à rupture membranaire veille "ε_r"), On a procédé à une analyse de sensibilité par méthode de poids.

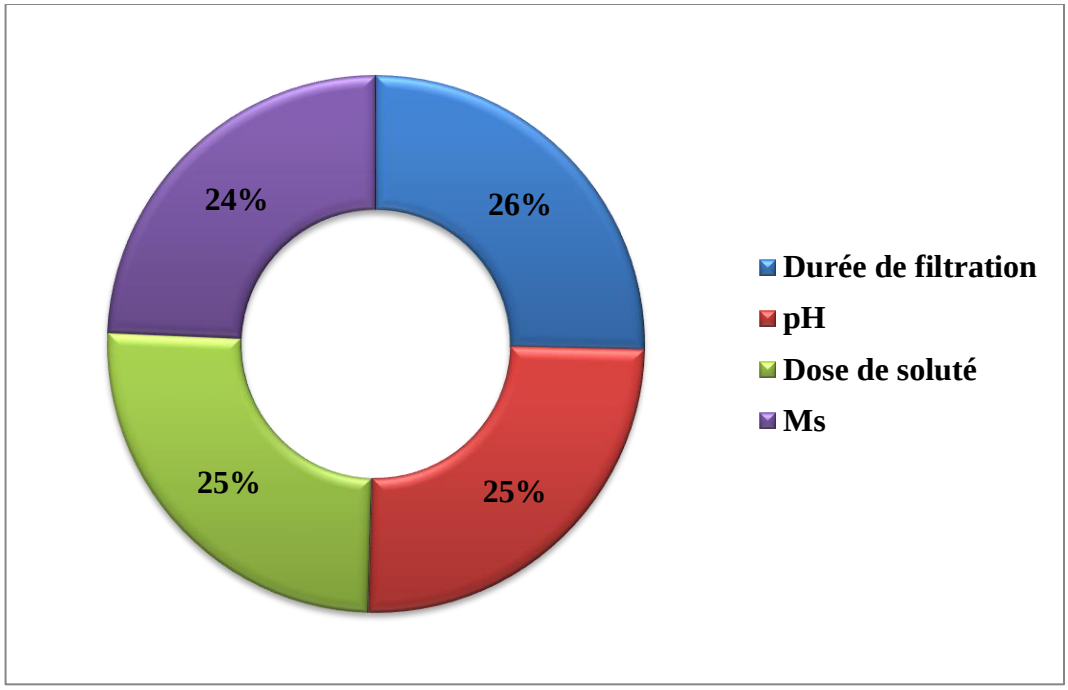
Nous avons appliqué cette méthode aux RN1, RN2, RN3 en utilisant leurs poids respectifs illustrés dans les tableaux III.12, III.13 et III.14. Les résultats de contributions sont montrés sur la figure III.10. D'après la figure III.10 (a) on constate que les variables les plus pertinentes qui peuvent influer sur la perméabilité de l'eau sont : pH (IR = 17%), dose de HOCL (IR = 17%), molarité (IR = 16%), pression (IR = 17%), Ms (IR = 16%) et durée de filtration (IR = 17). La figure III.10 (b) montre que les variables les plus pertinentes qui peuvent influer sur la perméabilité de soluté sont : Ms (IR = 16.89%), Molarité (IR = 16.71%), pH (IR = 16.68%), pression (IR=16.57%), durée de filtration (IR =16.49) et dose de HOCL (IR = 16.66%). La figure III.10 (c) montre que les variables les plus pertinentes qui peuvent influer sur l'allongement à rupture membranaire veille sont : durée de filtration (IR = 26), Molarité (IR = 25%), pH (IR = 25%) et Ms (IR=24%). Toutes les entrées exercent les contributions les plus importantes.


16%
17%
16%
17%
17%
17%
Durée de filtration
pH
Pression
Dose HOCL
Molarité
Ms

(a)


16.89%
16.49%
16.71%
16.68%
16.66%
16.57%
Durée de filtration
pH
Pression
Dose HOCL
Molarité
Ms

(b)



(c)

Figure III.10. Présentation des pourcentages de l'importance relative (*IR*) de chaque variable d'entrée sur la perméabilité de l'eau et la perméabilité de soluté et l'allongement à rupture membranaire vieille : (a) RN1, (b) RN2 et (c) RN3.

III.7. Diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimisé

Les diagrammes de dispersions des modèles optimisés ont montré un certain nombre des points éloignés de la première bissectrice que nous avons attribué à l'existence probable de points aberrants. Ceci nous a motivé à réaliser un diagnostic des données potentiellement suspectes selon la méthode décrite dans les deux références suivantes (Hosseinzadeh et Hemmati-Sarapardeh 2014).

Les valeurs aberrantes sont bien connues en tant que points de données distincts de la tendance générale des principaux points de données. La détection des valeurs aberrantes, qui joue un rôle important dans la proposition de modèles, est utilisée pour reconnaître des données individuelles (ou des groupes de données) pouvant différer de la masse des données constituant un ensemble de données. À cette fin, il est essentiel de trouver des méthodes rigoureuses pour détecter les valeurs potentiellement suspectes afin d'éliminer des données expérimentales inexactes et d'améliorer la précision des modèles (Hossein zadeh et Hemmati-Sarapardeh 2014). Dans cette étude, la technique mathématique "Leverage" a été utilisée pour rechercher les valeurs aberrantes. Dans cette technique,

les valeurs résiduelles sont d'abord calculées. Ensuite une matrice H de points de données d'entrées créée sur la base de la formule suivante :

$$H = X(X^tX)^{-1}X^t \quad (III.15)$$

Où X fait référence à la matrice m × n (m et n représentent respectivement le nombre d'échantillons et les paramètres (variables d'entrée) du modèle). Les valeurs de Hat sont obtenues à partir de la diagonale principale de la matrice de H.

$$Hat = diagonale(H) \quad (III.16)$$

Le diagramme de William qui représente les résidus normalisés en fonction du "Leverage" levier (Hat) peut détecter graphiquement les valeurs aberrantes. Dans ce graphique, le levier critique (H^*) (seuil) est généralement fixé à la valeur donnée par l'équation suivante :

$$H^* = \frac{3(n+1)}{m} \quad (III.17)$$

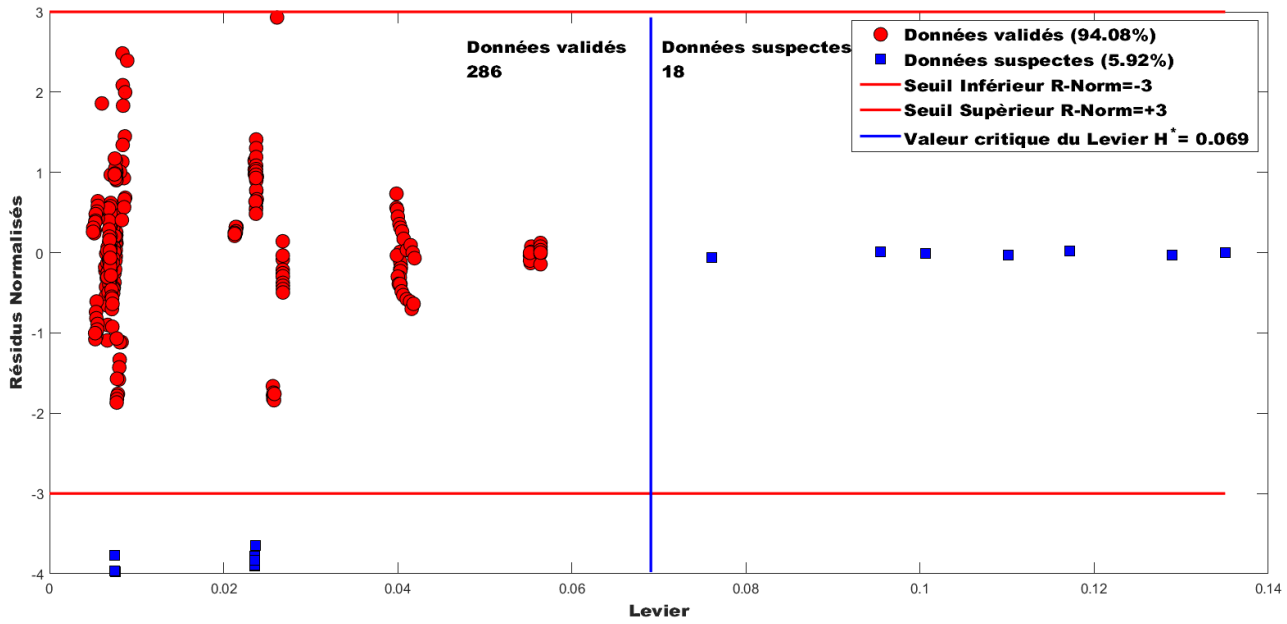
Où m et n représentent respectivement le nombre d'échantillons et les paramètres (variables d'entrée) du modèle.

Les résidus normalisés sont calculés à partir des données de la sortie expérimentale et celle calculée par le modèle.

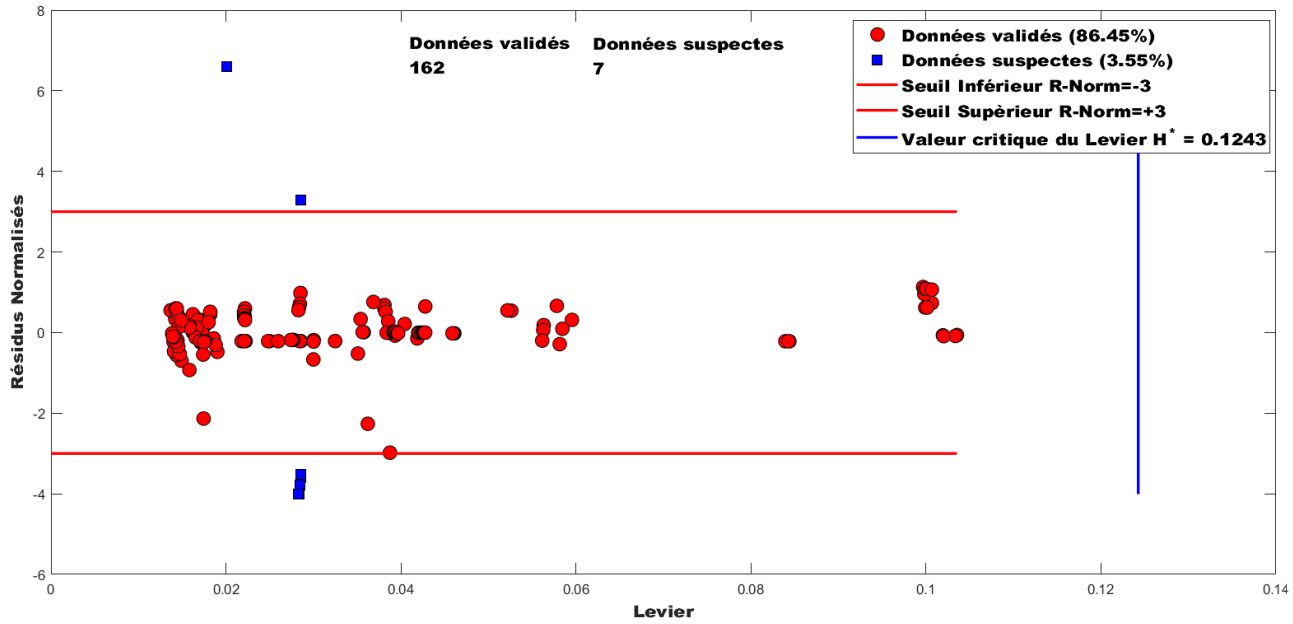
$$(R_Norm)_i = \frac{(y_i^{exp} - y_i^{cal})}{\sqrt{var(y^{exp} - y^{cal})}} \quad i = 1, \dots m \quad (III.18)$$

Le résidu normalisé égal à trois est normalement considéré comme une valeur "seuil" pour accepter les points de données dans les écarts types compris sur une plage de ± 3 par rapport à la moyenne (pour couvrir 99% des données normalement distribuées). Si la majorité des points de données se situent dans les plages de $0 \leq Hat \leq H^*$ et de $-3 \leq R_Norm \leq 3$, cela indique que le développement du modèle et ses prédictions sont effectués dans le domaine d'applicabilité, ce qui conduit à un modèle statistiquement valide. Ainsi on peut affirmer qu'il existe des points ‘’Good High Leverage’’ dans le domaine de $0 \leq Hat \leq H^*$ et $-3 \leq R_Norm \leq 3$. Les points situés dans la plage de $R_Norm < -3$ ou $R_Norm > 3$ (qu'ils soient plus grands ou plus petits que la valeur H^*) sont désignés comme points aberrants du modèle ou comme points "Bad High Leverage".

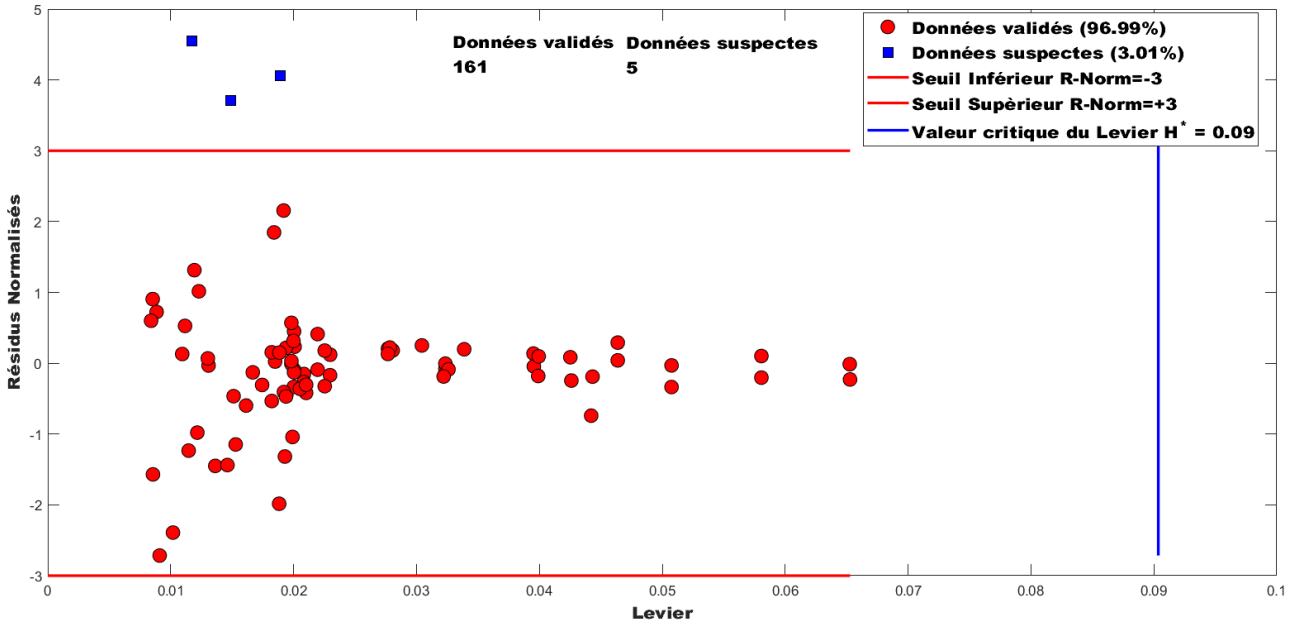
La figure III.11 montre le diagramme de William pour le domaine d'applicabilité des modèles neuronaux optimaux (a) pour RN1, (b) pour RN2 et (c) pour RN3. Dans la figure III.8 (a) il existe de **286/304 (93.33%)** de points de données valides et **18/304 (5.92%)** de points de données suspectes. La valeur critique de levier $\boldsymbol{H^* = \frac{3(n+1)}{m} = \frac{3(6+1)}{304} = 0.069}$ pour la phase totale. Dans la figure III.11 (b) il existe de **163/169(96.45%)** de points de données valides et **6/169 (3.55%)** de points de données suspectes. La valeur critique de levier $\boldsymbol{H^* = \frac{3(n+1)}{m} = \frac{3(6+1)}{169} = 0.1243}$ pour la phase totale. Dans la figure III.11 (c) il existe de **161/166(96.99%)** de points de données valides et **5/166 (3.01%)** de points de données suspectes. La valeur critique de levier $\boldsymbol{H^* = \frac{3(n+1)}{m} = \frac{3(4+1)}{166} = 0.0903}$ pour la phase totale. Cela indique que le développement de chaque modèle neuronal optimal (RN1, RN2 et RN3) et sa prédiction est effectué dans le domaine d'applicabilité Ce qui conduit à des modèles neuronaux optimaux statistiquement valides. Ainsi on peut affirmer qu'il existe des points "Good High Leverage" pour la phase totale de chaque réseau de neurones.



(a)



(b)



(c)

Figure III.11. Diagnostic des données potentiellement suspectes et domaine d'applicabilité du modèle neuronal optimal "RNA2" pour : (a) la phase test et (b) la phase de total.

III.8 Conclusion

Ce présent chapitre a donné une raison de plus pour l'utilisation généralisée des modèles neuronaux (RNA) pour la modélisation de la perméabilité de l'eau, de la perméabilité soluté et

l'allongement à rupture membranaire veille. Le but de la présente étude était de développer trois modèles RNA de type feed-forward.

Les modèles RNA optimaux optimisés développés dans ce travail ont donné des erreurs plus faibles.

- ✓ Les erreurs absolues moyennes "EAM" pour la phase de totale étaient 0.1158 (L/h.m^2.bar) pour RN1, 0.0888 (m/s) pour RN2 et pour 9.3660 (%) pour RN3 ;
- ✓ Les racines des erreurs quadratiques moyennes "REQM" étaient 0.1862 (L/h.m^2.bar) pour RN1 et 0.1829 (m/s) pour RN2 et 15.9252 (%) pour RN3 ;
- ✓ Les erreurs standards de prédictions "ESP" étaient 13.6028 (L/h.m^2.bar) pour RN1 et 23.9222 (m/s) pour RN2 et 20.3942 (%) pour RN3.

L'analyse de sensibilité par la méthode de poids a révélé que les variables les plus importantes qui influent de la membrane vieille sont :

- ✓ Perméabilité de l'eau "Aw" : pH (IR = 17%), dose de HOCL (IR = 17%), molarité (IR = 16%), pression (IR = 17%), Ms (IR = 16%) et durée de filtration (IR = 17) ;
- ✓ Perméabilité de soluté "As" : Ms (IR = 16.89%), Molarité (IR = 16.71%), pH (IR = 16.68%), pression (IR=16.57%), durée de filtration (IR =16.49) et dose de HOCL (IR = 16.66%) ;
- ✓ Allongement à rupture membranaire veille "ε_r" : durée de filtration (IR = 26), Molarité (IR = 25%), pH (IR = 25%) et Ms (IR=24%).

Analyse diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimal a montré que le développement de chaque modèle neuronal optimal (RNA1, RN2 et RNA3) et sa prédiction est effectué dans le domaine d'applicabilité. Ce qui conduit à des modèles neuraux optimaux statistiquement valides. Ainsi on peut affirmer qu'il existe des points "Good High Leverage" pour la phase de totale pour chaque modèle neuronal optimal (RN1, RN2 et RN3).

Conclusion générale et perspectives

Les réseaux de neurones possèdent une propriété remarquable dont l'apport est manifesté pour la modélisation des processus non linéaires : ce sont des approximateurs universels parcimonieux. Les modèles des réseaux neurones artificiels (RNA) ont finalement été appliqués pour la prévision de la perméabilité de l'eau et soluté lors des membranes d'osmose inverse vieille qui ont été abordés par d'autres chercheurs d'une façon réductible dont la taille de la base de données et les paramètres calculés ont donné des résultats encourageants.

L'objectif de ce mémoire a porté sur l'utilisation des réseaux de neurones pour la modélisation du processus de la perméabilité de l'eau, la perméabilité de soluté et l'allongement à rupture des membranes d'osmose vieilles. Les trois modèles neuronaux de type feedforward (RN) caractérisés par une structure (six neurones pour RN1 et RN2, quatre neurones pour RN3 dans la couche d'entrée, une couche cachée et un neurone dans la couche de sortie) sont construits dans le but de prédire la perméabilité de l'eau, la perméabilité de soluté, l'allongement à rupture des membranes vieilles. Une bonne concordance, entre les valeurs expérimentales et les valeurs prédites, pour chaque modèle neuronal a été obtenue (les racines des erreurs quadratiques moyennes pour la phase totale étaient (0.1862 (L/h.m^2.bar) pour RN1 et 0.1829 (m/s) pour RN2 et 15.9252 (%) pour RN3).

L'analyse de sensibilité par la méthode de poids a révélé que les variables les plus importantes qui influent de la membrane vieille sont : pH (IR = 17%), dose de HOCL (IR = 17%), molarité (IR = 16%), pression (IR = 17%), Ms (IR = 16%) et durée de filtration (IR = 17) pour la perméabilité de l'eau "Aw"; Ms (IR = 16.89%), Molarité (IR = 16.71%), pH (IR = 16.68%), pression (IR=16.57%), durée de filtration (IR =16.49) et dose de HOCL (IR = 16.66%) pour la perméabilité de soluté "As" ; durée de filtration (IR = 26), Molarité (IR = 25%), pH (IR = 25%) et Ms (IR=24%) pour l'allongement à rupture membranaire veille"ε_r"

Analyse diagnostic des points aberrants et domaine d'applicabilité du modèle neuronal optimal a montré que le développement de chaque modèle neuronal optimal (RNA1, RN2 et RNA3) et sa prédiction est effectué dans le domaine d'applicabilité. Ce qui conduit à des modèles neuraux optimaux statistiquement valides. Ainsi on peut affirmer qu'il existe des points "Good High Leverage" pour la phase de totale pour chaque modèle neuronal optimal (RN1, RN2 et RN3).

A la lumière des résultats obtenus on peut tirer les conclusions suivantes :

- ✓ Les réseaux de neurones sont des outils statistiques, qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points comme toute méthode statistique ;
- ✓ Les réseaux de neurones fonctionnent comme une boite noire et les paramètres du réseau (poids et biais) n'ont pas de signification physique. L'application des réseaux neuronaux ne développe pas directement de la théorie de description du système, mais rend faisable la modélisation et la simulation des procédés de fermentation ;
- ✓ La modélisation par réseau de neurones est une méthode qui est basée seulement sur des données expérimentales et/ou semi-expérimentales (déduites des modèles analytiques, empiriques, numériques, …), donc la qualité et la quantité de données décident de l'exactitude et la robustesse du modèle ;
- ✓ Les réseaux de neurones peuvent être très robustes et performants même en présence de peu de données expérimentales à condition que ces dernières soient statistiquement bien réparties dans le domaine d'entrée du modèle neuronal, ce qui est le cas avec le plan composite centré ;
- ✓ Les formules mathématiques extraites des modèles neuronaux peuvent trouver des applications intéressantes dans la prédiction, l'optimisation et même le contrôle des procédés d'osmose inverse et de nanofiltration.

Donc le réseau neurone artificiel constitue un outil de modélisation convenable dans le cas de de la perméabilité de l'eau et soluté lors des membranes d'osmose inverse vieille qui permettra de réduire la défaillance des modèles classiques de modélisation avec une précision intéressante et pourra être mis à la disposition des managers en vue de l'élaboration des boucles de contrôle.

De ce travail de mémoire ont émergé de nombreuses pistes de recherche qui feront l'objet de futurs travaux.

- ✓ Les perspectives concernent plus particulièrement la modélisation de la perméabilité de l'eau et soluté lors des membranes vieilles, mais en utilisant d'autres paramètres, on propose de faire une étude avec des propriétés interfaciales et structurelles des polymères.
- ✓ Nous pouvons aussi étendre l'idée de ce travail à d'autres méthodes de l'intelligence artificielle (Support vecteur machine, Réseaux de neurones multiples,…).

Références Bibliographiques

Ait khaldoun. I. (2011). "Optimisation du transport des cations Cu (ii), Zn (ii) et cd (ii) par le tri-n butyle phosphate (tbp) A travers les membranes d'affinité". Mémoire de master Université de mouloud Mammeri de Tizi-Ouzou. Tizi-Ouzou. Algérie.

Allgeier S. (2001). "Overview of regulatory issues facing microfiltration and ultra-filtration, Proceedings of the 2001 Membrane Technology". Conference of the American Water works association, san-Antonio, Texas, USA.

Ammi Y., Khaouane L. et Hanini S (2021). "Stacked neural networks for predicting the membranes performance by treating the pharmaceutical active compounds". Neural Computing and Applications. **33** (12429–12444).

Ammi Y. (2016) "Modélisation des phénomènes de transport lors d'osmose inverse". Thèse de doctorat, Université de Yahia Farés de Médéa. Médéa. Algérie.

Annane K. (2015). "Extraction et transport des ions de cadium (II) par membranes d'affinité dans des dispositifs micro fluidiques". Thèse de doctorat. Université de Mouloud Mammeride Tizi-Ouzou. Tizi-Ouzou. Algérie.

Aptel Ph. et Buckley C. A. (1996). "Categories of membrane operations, In : Water Treatment Membrane Process ". Chapitre 2, McGraw-Hill : 24.

Axel E. (2011). "Vieillissement chimique de membranes d'osmose inverse". Thèse de doctorat de l'université de Toulouse. France.

Azizi A. (2011). "Modélisation des phénomènes de transports lors de l'osmose inverse Application aux molécules inorganiques et organiques en amont et en aval d'une unité de production pharmaceutique". Thèse de magister. Université de Yahia Farés. Médéa. Algérie.

Basheer I.A. et Hajmeer M. (2000). "Artificial neural networks: Fundamentals, computing, design and application" Journal of Microbiological Methods **43** (1): 3-31.

Benavente J. Vázquez M.I. (2004). "Effect of age and chemical treatments on characteristic parameters for active and porous sublayers of polymeric composite membranes, Journal of Colloid and Interface Science. 273 :547-555

Benmerak W. et Zahraoui F (2022). "Modélisation du vieillissement lors de la filtration membranaire". Mémoire de master. Université Yahia Farès de Médéa.

Bishop C. M. (1995). "Neural networks for pattern recognition." Oxford University. Press. New York. USA.

Boudjnane Z. (2018). "Synthèse des membranes à base de polymères et d'argile". Thèse de magister. Université de Abou-BekrBelkaid. Tlemcen. Algérie.

Bryjak J. Ciesielski K. et Zbicinski I. (2004)."Modeling of glucoaylase: thermal inactivation in the presence of starch by artificial neural network". Journal of Biotechnology **114** (1-2): 177-185.

Carpenter G.A. et Grossberg S. (1987). "ART 2: Self-organization of stable category recognition codes for analog input patterns." Applied optics **26**(23): 4919-30.

Carpenter G.A. et Grossberg S. (1988). "The ART of adaptive pattern recognition by a self-organizing neural network". Computer **21** (3): 77-88.

Chabane M. (2015). "Étude de la résistance au colmatage et de la rétention des composes toxiques par membranes". Thèse de doctorat. Université d'Aboubekr Belkaid de Tlemcen. Tlemcen. Algérie.

Chellam S. Jacangelo J.G. (1997). "Effect of Pretreatment on surface water nanofiltration". Journal of Awwa. **89** (10). P 77-89.

Chikhi M. (2008). "Etude de la complexassions des cations métalliques en vue de leur séparation par un procédé membranaire". Thèse de doctorat. Université Mentouri. Constantine. Algérie.

Campbell N. et Jane B. (2007). "Biologie Erpi". Montréal. Canada. Reece.

Dames M. (2005) : "Gestion de procèdes discontinus : Méthodologie de modélisation et d'optimisation d'opérations de dispersion liquide-liquide en cuve agitée." Thèse de Doctorat. Institut National Polytechnique de Toulouse. Toulouse. France.

Demuth H. et Beale M. (2000): "Neural network toolbox for use with Matlab". User's Guide version 4. USA. the Math Works Inc.

Garson G.D. (1991): "Interpreting neural-network connection weights". Artificiel Intelligence Expert. **6** (4): 46-51.

Gevrey M. Dimopoulos I. et Lek S. (2003): "Review and comparison of methods to study the contribution of variables in artificial neural network models". Ecological Modeling. 160 (3): 249-264.

Goh A.T.C. (1995)."Back-propagation neural networks for modeling complex systems". Artificial Intelligence in Engineering **9** (3): 143-151.

Hemmati-Sarapardeh A. Majidi S. M. J. Mahmoudi B. Ramazani S. A. A. et Mohammadi A. (2014). "Experimental measurement and modeling of saturated reservoir oil viscosity". Korean Journal of Chemical Engineering **31** (7): 1253-1264.

Hopfield J.J. (1982):"Neural networks and physical systems with emergent collective computational abilities." Proceedings of the National Academy of Sciences **79**(8): 2554-2558.

Jensen J.S. Lam Y-F. Helz G.R (1999). "Role amide nitrogen in water chlorination: Proton NMR evidence". Environmental Science and Technology. 33. 3568-3573.

Jean-Pierre (2010) : "Biocontact. n°200. Buvez vos légumes. Camo. p.3.

Kang G.D. Gao C-J. Chen W-D. Jie X-M. Cao Y-M. Yuan Q. (2007)." Study on hypochlorite degradation of aromatic polyamide reverse osmosis membrane". Journal of Membrane Science. 300. 165-171.

Khaouane L. (2013). "Etude et Modélisation de la Biosynthèse des Antibiotiques à partir de Différentes Souches Productrices – Cas de bleuro mutiline". Thèse de doctorat. Université de Médéa. Algérie.

Kherbache S. et Ben labiod Y. (2022). " Prédiction des Propriétés Optiques du Sang par Réseaux de Neurones Artificielles ". Mémoire de master. Université Yahia Farès de Médéa.

Knoell T. Martin E. Ishida K. Phipps D. (2005). "The effect of chlorine exposure on the performance and properties of polyamide reverse osmosis membranes". Awwa Membrane Technical. Conference proceedings.

Kohonen T. (1982). "Self-organized formation of topologically correct feature maps." Biological Cybernetics 43(1): 59-69.

Koo J-Y. Lee J.H. Jung Y.D. Hong S.P. Yoon S.R. (2009). "chlorine resistant membrane and the mechanism of membrane degradation by chlorine". Awwa Membrane Technology Conference proceedings.

Kwon Y-N. et Leckie J.O (2006)." Hypochlorite degradation of cross linked polyamide membranes II.Changes in hydrogen bonding behavior and membrane performance". Journal of Membrane Science. 282. 456-464.

Kwon Y-N. Tang C.Y. Leckie J.O. (2006)."Change of membrane performance due to chlorination of cross-linked polyamide membranes". Journal of Applied Polymer Science. 102. 5895-5902.

Laidi M. (2009). "Approche neuronale pour l'estimation du coefficient de diffusion moléculaire apparent dans Un milieu poreux anisotrope bois ". Thèse de magister. Université de Yahia Farés. Médéa. Algérie.

Lanteri Y. (2009). "Transport à travers des membranes de nanofiltration : caractérisation des propriétés électronique. Thèse de doctorat. Université de Franche-Comté. Besancon. France.

Lozier J.C. (2005)."Evaluating chloramines for control of RO membrane biofouling with ground and surface water supplies". Awwa Membrane Technology Conference proceedings.

Marar L et Mouas R. (2019). "Modélisation numérique d'un écoulement à l'intérieur d'un module membranaire ".

Metaiche M. (2014). "Technologie membranaire". Faculté des sciences et des sciences appliquées de l'université de Bouira. Algérie. Chapitre 1: 4-6.

Moody J. et Darken C. J. (1989)." Fast learning in networks of locally-tuned processing units" neural computation 1(2): 281 - 294.

Nilsson M., Trägardh G., Östergren K., (2008)."Influence of temperature and cleaning on aromatic and semi-aromatic polyamide thin-film composite NF and RO membranes". Separation and Purification Technology, 62:717-726.

Rabuni M. F. Sulaiman N. M. N. Aroua M. K. CheeC. Y. Hashim N. A (**2015).** "Impact of in situ physical and chemical cleaning on {PVDF} membrane properties and performances". Chem. Eng. Sci.122. 426 – 435.

Ravereau-Delattre J. (2015). "Étude du vieillissement en milieu chloré de membranes fibres creuses en poly (fluorure de vinylidène) utilisées dans le traitement de l'eau". Thèse de doctorat. de l'école Nationale Supérieure d'Arts et Métiers paris.

RosenblattF. (1958). "The perceptron: A probabilistic model for information storage and organization in the brain." Psychological Reviews 65 (6): 386-408.

Serna F. García F. De LaPeña J.L. Calderón V. García J.M. (2007). "Properties characterization and preparation of halogenated aromatic polyamides". Journal of Polymer Research. 14. 341-350.

Simon A. Nghiem L.D. Le-Clech P. Khan S.J. Drewes J.E. (2009). " Effects of membrane Degradation on the removal of pharmaceutically active compounds (PhACs) by NF/RO filtration processes". Journal of Membrane Science. 340. 16-25.

Stone M. (1977). "An asymptotic equivalence of choice of model by cross-validation and Akaike's criterion." Journal of the Royal Statistical Society B 39(1): 44-47.

Si-Moussa C. (2010). "Modélisation des équilibres de phases a pressions élevées par les réseaux de neurones artificiels". Thèse de doctorat. École nationale supérieure polytechnique. Alger. Algérie.

Talbi M L. (2011). "Analyse et traitement du signal électro cardiographique (ECG)." Thèse de Doctorat. Université mentouri de Constantine. Constantine, Algérie.

Verdu J. (1984). "Vieillissement des plastiques." Afnor technique ISSN 0297-6714.

Verdu J. (2002). "Différents types de vieillissement chimique des plastiques." techniques de l'ingénieur (AM3152).

Verdu J. (1990). "Vieillissement chimique des plastiques " techniques de l'ingénieur (A3151).

Verdu J. (2002). "Vieillissement chimique des plastiques." Techniques de l'ingénieur (AM 3152).

Yangjeh A.H. et Jenagharad M.D. (2009). "Application of a genetic algorithm and an artificial neural network for global prediction of the toxicity of phenols to Tetrahymena pyriformis". Monatsh Chem. 140: 1279.