

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي و البحث العلمي

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITÉ BADJI MOKHTAR –

جامعة باجي مختار

ANNABA

عنابة



FACULTÉ DES SCIENCES
DÉPARTEMENT DE BIOLOGIE

Thèse En vue de l'obtention d'un Diplôme de Doctorat es sciences

Domaine : SCIENCES DE LA NATURE ET DE LA VIE

Filière : Biologie

Spécialité : Biologie végétale et environnement

Intitulé

« Contribution des réseaux de neurones artificiels à l'évaluation de la pollution (Cas de la zone industrielle de Skikda) ».

Presentée par : MELLAL Nour El Houda

Directrice de thèse : TAHAR Wafa (MCA, Université Badji Mokhtar - Annaba)

Devant le jury composé de :

Pr. BOUKHROUFA Ferial	Présidente	Université Badji Mokhtar - Annaba
MCA. ROUIDI Sonia	Examinatrice	Université du 20 Août 1955 -Skikda
MCA. SLIMANI Abderachid	Examineur	Université Badji Mokhtar - Annaba
MCA. KHELFAOUI Hakim	Examineur	Université du 20 Août 1955 -Skikda
MCA. SELMANE Mehdi	Examineur	Université Hamma Lakhdar -El Oued

Abstract

The main objective of this research is to determine how wastewater discharged from a wastewater treatment plant (WWTP) in a petroleum complex affects the environment. Using the water quality index (WQI) as a thorough assessment tool, the study looks at how essential factors, including temperature, pH, phosphates, and hydrocarbons from an oil refining complex wastewater treatment plant, affect water quality. The initiative aims to contribute to water resource management and environmental monitoring. The machine learning models were trained using principal component analysis (PCA) data, constituting 70% of the entire dataset. The findings show significant seasonal variations in the water quality indexes, with the most significant values observed in the spring (37.92), summer (49.34), winter (32.96), and fall (40.66). The ANN and RSM-BBD models exhibited excellent predictive accuracy in estimating experimental data, as evidenced by high determination coefficients (R^2). For the Artificial Neural Network (ANN) model, R^2 values for the Water Quality Index in the fall, winter, spring, and summer were, respectively, 0.9897, 0.9834, 0.9909, and 0.9956. The Response Surface Methodology-Box-Behnken Design (RSM-BBD) model's R^2 values for the corresponding seasons were 0.9279, 0.9378, 0.9802, and 0.98866. However, the ANN model performed better than the RSM-BBD model; both models indicated the ability to forecast water quality parameters. By providing extensive data on seasonal fluctuations in water quality indicators, the study advances our understanding of the ecological implications of discharged water from petroleum complexes.

Keywords: Water quality index, Artificial Neural Network, Response Surface Methodology, industrial pollution, Wastewater Treatment Plant, Petroleum complex.

هذه الدراسة تركز على المسألة الأساسية لتقييم التأثير البيئي لمياه الصرف الصحي المعالجة في محطة التنقية (STEP) في مجمع تكرير النفط. تفحص الدراسة تأثير المؤشرات الرئيسية مثل درجة الحموضة (pH) ودرجة الحرارة والفوسفات والهيدروكربونات الناتجة عن محطة المعالجة، باستخدام مؤشر جودة المياه (WQI) كمقياس شامل للتقييم يهدف إلى مساعدة في إدارة موارد المياه وحماية البيئة. تم تدريب نماذج التعلم الآلي باستخدام بيانات تحليل المكونات الرئيسية (ACP) التي شكلت 70% من مجموع البيانات. تشير النتائج إلى اختلافات موسمية كبيرة في مؤشرات جودة المياه، حيث تم ملاحظة أعلى القيم في فصل الخريف (40.66)، الشتاء (32.96)، الربيع (37.92)، والصيف (49.34). أظهرت نماذج ANN و RSM-BBD دقة توقع ممتازة في تقدير البيانات التجريبية، كما أشارت القيم العالية لمعاملات التحديد (R^2) كانت قيم (R^2) لمؤشر جودة المياه (WQI) في فصل الخريف والشتاء والربيع والصيف على التوالي 0.9897، 0.9834، 0.9909، و 0.9956 لنموذج الشبكة العصبية الاصطناعية (ANN) بالنسبة لنموذج RSM-BBD (منهجية السطح الاستجابي - تصميم بوكس-بينكين)، كانت القيم R^2 تبلغ 0.9279، 0.9378، 0.9802، و 0.98866 لنفس الفصول. أظهر النموذجان فعالتهما في التنبؤ بمؤشر جودة المياه على الرغم من أن نموذج ANN أكثر فعالية من نموذج RSM-BBD. مما يعزز فهمنا للأثار البيئية لمياه الصرف الصحي التي يتم صرفها من مجمعات تكرير النفط من خلال توفير معلومات مفيدة حول التغيرات الموسمية في مؤشرات جودة المياه.

الكلمات المفتاحية: مؤشر جودة المياه، الشبكات العصبية الاصطناعية، منهجية استجابة السطح، التلوث الصناعي، محطة معالجة مياه الصرف الصحي، مجمع تكرير البترول.

Résumé

Cette étude porte sur la question fondamentale de l'évaluation de l'impact environnemental des eaux usées rejetées par la station d'épuration (STEP) du complexe de raffinage de pétrole. L'étude examine l'impact des paramètres clés tels que le pH, la température, les phosphates et les hydrocarbures provenant de la STEP, en utilisant l'indice de qualité de l'eau (WQI) comme mesure globale d'évaluation dont l'objectif est d'aider à la gestion des ressources en eau et de surveiller l'environnement. Les modèles de machine Learning ont été formés à l'aide des données de l'analyse en composantes principales (ACP), qui constituaient 70 % de l'ensemble des données. Les résultats indiquent des variations saisonnières significatives des indices de qualité de l'eau, les valeurs les plus élevées étant observées en automne (40,66), en hiver (32,96), au printemps (37,92) et en été (49,34). Les modèles ANN et RSM-BBD ont fait preuve d'une excellente précision prédictive dans l'estimation des données expérimentales, indiquée par les coefficients de détermination élevés (R^2). Les valeurs du coefficient de détermination (R^2) pour l'indice de qualité de l'eau (WQI) en automne, en hiver, au printemps et en été étaient respectivement de 0,9897, 0,9834, 0,9909 et 0,9956 pour le modèle de réseau de neurones artificiel (ANN). Pour le modèle RSM-BBD (Response Surface Methodology-Box-Behnken Design), les valeurs R^2 étaient de 0,9279, 0,9378, 0,9802 et 0,98866 pour les mêmes saisons. Les deux modèles ont démontré leur efficacité dans la prévision de l'indice de qualité de l'eau bien que le modèle ANN soit plus performante que le modèle RSM-BBD. L'étude améliore notre compréhension des implications écologiques des eaux rejetées par les complexes pétroliers en fournissant des informations utiles sur les variations saisonnières des indices de qualité de l'eau.

Mots clés : Indice de qualité de l'eau, Réseaux de neurones artificiels, Méthode de surface de réponse, Pollution industrielle, Station d'épuration des eaux usées, Complexe de raffinage de pétrole.

Dédicaces

*Je dédie ce travail à mes parents, mes frères et sœurs,
mon époux et mes enfants pour leur soutien moral, leurs
encouragements et leur compréhension qui ont été
essentiels pour moi tout au long de cette expérience.*

REMERCIEMENTS

Je remercie Allah le tout puissant de m'avoir guidé et soutenu, c'est grâce à sa miséricorde que j'ai pu surmonter les défis et atteindre la fin de ce travail.

Ce travail n'aurait pu avoir lieu sans l'appui de plusieurs personnes que je vais tâcher de remercier ici, en espérant ne pas oublier les autres ;

Je souhaite exprimer ma profonde gratitude à Monsieur Ali TAHAR, professeur à l'université de Badji Mokhtar Annaba, pour sa direction avisée tout au long de ces années. Ses conseils éclairés et son expérience ont été d'une aide inestimable dans l'accomplissement de ma thèse. Alors qu'il a pris sa retraite, je suis reconnaissante qu'il ait choisi sa fille Mme Wafa TAHAR, maître de conférence A, pour assurer la continuité de ce projet. Je tiens également à la remercier pour son engagement à poursuivre le travail initié par son père.

Je tiens aussi à remercier Madame Feriel BOUKHROUFA, professeur à l'université de Badji Mokhtar Annaba pour m'avoir fait un grand honneur en acceptant de présider le jury.

Mes remerciements vont également à Mme Sonia Rouidi, maître de conférence classe A à l'université du 20 août 1955 Skikda, pour l'intérêt qu'elle a accordé à ma thèse et le regard aiguisé sur mon travail. Je lui suis reconnaissante de m'avoir encouragée dans cette expérience et d'avoir accepté d'examiner mon travail.

Je tiens à remercier vivement Mr Abderrachide SLIMANI, maître de conférence classe A et chef de département à l'université de Badji Mokhtar Annaba, de sa précieuse contribution à faciliter la démarche de soutenance et à franchir cette étape importante. Je suis honorée de bénéficier de son accord pour examiner mon travail.

J'exprime ma profonde gratitude et ma reconnaissance à Mr Hakím KHALFAOUI, maître de conférences classe A à l'université du 20 août 1955 Skikda, d'avoir accepté d'examiner ce travail, c'est un honneur pour moi de pouvoir bénéficier de son expertise.

Mes sincères remerciements vont également à Monsieur Mehdi SELMANE, maître de Conférences Classe A à l'Université de Hamma Lakhdar El Oued, d'avoir accepté d'examiner ce travail.

Enfin, je souhaite adresser ma profonde reconnaissance à ceux qui ont contribué de près ou de loin à la réussite de ce travail.

Liste des Tableaux

Tableau V.1. Résumé des statistiques descriptives des paramètres physicochimiques	58
Tableau V.2. Répartition des valeurs propres (Eigenvalues)	64
Tableau V.3. Coefficients de corrélations entre les trois premières composantes principales et les différentes variables.	65
Tableau V.4. Contributions des variables à la formation des différentes composantes principales	66
Tableau V.5. Matrice de corrélations	67
Tableau V.6. Ordre de présentation des différentes variables	68
Tableau V.7. Classification des différents modèles d'entrée selon la valeur de Gamma (Γ)	69
Tableau VI.1. Développement des niveaux de test	71
Tableau VI.2. Analyse de la variance (ANOVA) de l'indice de qualité des eaux usées traitées à la raffinerie à pas de temps saisonnier.	74
Tableau VI.3. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'automne.	80
Tableau VI.4. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'hiver.	81
Tableau VI.5. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données de printemps.	82
Tableau VI.6. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'été.	83
Tableau VI.7. Les réponses optimisées des paramètres physico-chimiques via une approche numérique.	87
Tableau VII.1. Performances des modèles ANN lors de l'apprentissage, validation et de test.	91
Tableau VII.2. Modèles mathématiques de l'indice de qualité de l'eau usée traitée à la STEP de la raffinerie pour les quatre saisons.	96
Tableau VII.3. Performances des modèles utilisés pour la prévision des indices de qualité de l'eau (Mellal et al., 2024)	101

Liste des figures

Figure III.1. Analogie entre le neurone biologique et le neurone artificiel	27
Figure IV.1 : (a) Carte de l'Algérie, (b) Situation du complexe de raffinage de pétrole (RA1/K) de Skikda.	37
Figure IV.2. Précipitations moyennes mensuelles de Skikda (ONM, 2022).	39
Figure IV.3. Températures moyennes mensuelles de Skikda (ONM, 2022).	39
Figure IV.4. Diagramme ombrothermique de Gaussen de Skikda (ONM, 2022).	40
Figure IV.5. Station d'épuration des eaux usées de la RA1/K Skikda.	41
Figure IV.6. Traitement primaire	44
Figure IV.7. Traitement secondaire	46
Figure IV.8. Traitement de polissage	48
Figure V.1. Variations saisonnières du pH et la température de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.	77
Figure V.2. Variations saisonnières de la CE et PO_4 de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.	78
Figure V.3. Variations saisonnières de la DCO et $CxHy$ de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.	61
Figure V.4. Variations saisonnières de WQI de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.	62
Figures VI.1. Graphique de probabilité normale en fonction des résidus pour (a) automne, (c) hiver, (e) printemps et (g) été.	77
Figures VI.2. Courbes de variation saisonnière de WQI observé et prédit pour (b) automne, (d) hiver, (f) printemps et (h) été.	78
Figures VI.3. Diagrammes 3D et 2D de surface de réponse pour (a–b) WQI_{AUT} (pH- $CxHy$), (c–d) WQI_{WIN} (pH- $CxHy$) and (c-d) WQI_{SUM} (T- $CxHy$).	85
Figures VII.1. Architecture du réseau de neurone artificiel	89
Figures VII.2. Valeurs réelles de WQI comparées avec les valeurs prédites par le modèle ANN pour l'apprentissage, validation et test (a-c) WQI_{AUT} , (d-f) WQI_{WIN} , (g-i) WQI_{SPR} et (j-l) WQI_{SUM} .	94
Figures VII.3. Histogramme d'erreur pour (a) WQI_{AUT} , (b) WQI_{WIN} , (c) WQI_{SPR} and (d) WQI_{SUM}	95
Figures VII.4. Comparaison des valeurs réelles et prédites à l'aide des modèles ANN et RSM pour : (a) WQI_{AUT} , (b) WQI_{WIN} , (c) WQI_{SPR} and (d) WQI_{SUM} .	99

Liste des abréviations

ACF : Filtre à charbon activé

ACP : Analyse en composantes principales

Al: Aluminium

Alun : Sulfate d'aluminium

ANN : Réseaux de neurones artificiels

ANP : Analytic Network Process

As : Arsenic

BBD : Box-Behnken design

BCWQI : Indice de qualité de l'eau de la Colombie Britannique

BPNN : Réseau de neurone à rétropropagation

CCMEWQI : Indice de qualité de l'eau du conseil Canadien du ministère de l'environnement

Cd : Cadmium

COI : Concentré d'osmose inverse

COT : Carbone organique total

Cr : Chrome

Cu : Cuivre

CV : coefficient de variation

C_xH_y : Hydrocarbures totaux

DAF : Flottation à air dissous

DBO₅ : Demande biochimique en oxygène

DCO : Demande chimique en oxygène

DOE : Design of experiments

DOPE : polyélectrolyte de déshuilage

DRIK : Direction de la région industrielle de Skikda

Fe : Fer

HAP : Hydrocarbures aromatiques polycycliques

Hg : Mercure

IA : Intelligence artificielle

IRWQISC : Indice iranien de la qualité de l'eau pour les ressources en eau de surface-
paramètres conventionnels

JORA : Journal officiel de la république Algérienne

KMNO₄ : Permanganate de potassium

LM : Levenberg-Marquardt

MAPE : Pourcentage de l'erreur absolue moyenne

MES : matières en suspension

MLP : Perceptron multicouche

MLPNN : Réseaux de neurones artificiels à perceptron multicouches

MLR : Régression multilinéaire

MMBT : Réservoir à filtrant sur lit mobile

MSE : Erreur Quadratique Moyenne

Na₂C₂O₄ : Oxalates de sodium

NFSWQI : Indice de qualité de l'eau de la fondation nationale pour l'assainissement

NGL : Azote global

NH₃-N : Azote ammoniacal

Ni : Nickel

NO₂-N : les nitrites

NO₃-N : les nitrates

OAP : Organismes accumulateurs de phosphore ()

ONEDD : Observatoire national de l'environnement et du développement durable

OWS : Réservoir d'égalisation

Pb : Plomb

pH : Potentiel d'hydrogène

POA : Procédés d'oxydation avancée

PSF : Filtre à sable de pression

R : Coefficient de corrélation

R² : Coefficient de détermination

R² : Coefficient de détermination

RA1/K : Complexe de raffinerie de Skikda

RBFNN : Réseau neuronal à fonction de base radiale

RMSE : Racine Carrée de l'Erreur Quadratique Moyenne RMSE

RSM : Méthode de surface de réponse

SRDDWQI : Indice de qualité de l'eau du département Ecossais de développement de la recherche

STEP : Station d'épuration des eaux usées

TNK : Azote Kjeldahl total

TPI : Intercepteurs à plaque inclinée

WQI : Indice de qualité de l'eau

ZI : Zone industrielle

Zn: Zinc

Sommaire

Résumé

Liste des tableaux

Liste des figures

Liste des abréviations

	Introduction générale	1
Chapitre I :	Généralité sur la pollution industrielle	
	1. Introduction	7
	2. Sources et types de la pollution industrielle	7
	2.1. Pollution chimique	7
	2.2. Pollution physique	8
	2.3. Pollution biologique	8
	3. Indicateurs d'évaluation de la qualité des rejets	9
	3.1. Indicateurs généraux ou classiques	9
	3.1.1. Potentiel d'hydrogène (pH)	9
	3.1.2. Température	9
	3.1.3. Conductivité électrique (CE)	9
	3.1.4. Oxygène dissous (OD)	10
	3.2. Indicateurs globaux de pollution	10
	3.2.1. Matières en suspension (MES)	10
	3.2.2. Demande chimique en oxygène (DCO)	11
	3.2.3. Demande biologique en oxygène (DBO5)	11
	3.2.4. Turbidité	12
	3.2.5. Indice de biodégradabilité (I)	12
	3.2.6. Métaux lourds	12
	3.3. Indicateurs complémentaires	13
	3.3.1. Hydrocarbures	13
	3.3.2. L'Azote (N)	13
	3.3.3. Phosphore (PO4)	14
	3.3.4. Sodium (Na)	15
	4. Notion de risque lié à l'eau usée	15
	5. Conclusion	16
Chapitre II :	Techniques d'épuration des eaux usées	
	1. Introduction	17
	2. Procédés d'épuration des eaux usées	17
	2.1. Procédés physico-chimiques	17
	2.2. Procédés biologiques	18
	2.2.1. Epuration biologique aérobie	19
	2.2.2. Epuration biologique anaérobie	20
	a. L'hydrolyse	20
	b. Fermentation (l'acidogènes)	20
	c. L'acétogenèse des acides gras	20
	d. Méthanogenèse	21
	2.2.3. Epuration biologique combinée aérobie-anaérobie	21
	2.2.3.1. Avantages de l'épuration biologique combinée	21
	2.3. Procédés d'oxydation avancée (POA)	22
	2.4. Procédés électrochimiques	23
	2.5. Technologies membranaires	23
	3. Conclusion	24

Chapitre III : L'intelligence artificielle au service de l'évaluation de la pollution de l'eau

1.Introduction	25
2.Théorie des réseaux de neurones artificiels (ANN)	25
2.1. Historique des réseaux de neurones artificiels	25
2.2. Structure des réseaux de neurones artificiels ou neurone formel	26
2.3. Réseaux de neurones artificiels à perceptron multicouches (MLPNN)	28
2.4. Processus de modélisation des réseaux de neurones artificiels	29
3. Théorie de méthode de surface de réponse (RSM)	30
4. Critères d'évaluation de la qualité de prévision des modèles ANN et RSM	30
5. Indice de qualité de l'eau	32
5.1. Définition	32
5.2. Historique	32
5.3. Structure du modèle de WQI	33
6.Utilisation des ANN et RSM dans la modélisation de l'indice de qualité de l'eau	33
7.Conclusion	36

Chapitre IV : Présentation de la zone d'étude

1. Contexte géographique de la zone d'étude	37
2. Contexte réglementaire des eaux usées industrielles en Algérie	38
3. Contexte climatique de la zone d'étude	38
4. Description de la STEP de la raffinerie de Skikda (RA1/K)	41
4.1. Prétraitement	42
4.2. Traitement primaire	42
4.2.1. Grille et chambre à sable	42
4.2.2. Séparateur TPI	43
4.2.3. Réservoir d'égalisation	43
- Les réservoirs de mélange rapide	43
- Les réservoirs de floculation	43
4.2.4. Flottation à air dissous	44
4.3. Traitement secondaire	45
4.3.1. Ajustement de pH	45
4.3.2. Réservoir à filtrant sur lit mobile	45
4.3.3. Réservoir d'aération et clarificateur	45
4.4. Traitement de polissage	47
4.4.1. Filtre à sable de pression	47
4.4.2. Filtre à charbon activé	47
4.4.3. Bassin de protection	47
5. Echantillonnage et méthodes d'analyses des eaux usées	49
5.1. Mesure de la demande chimique en oxygène (DCO)	49
5.2. Dosage du phosphore total (PO_4^{-3})	50
5.3. Dosage des hydrocarbures totaux (C_xH_Y)	51
6. Calcul de l'indice de qualité de l'eau (WQI)	54
7.Conclusion	55

Chapitre V :	Identification des variables d'entrées par l'analyse en composante principale et Gamma test	
	1.Introduction	56
	2. Application de l'analyse en composante principale (ACP)	56
	2.1. Présentation de l'ACP	57
	2.2. Statistiques descriptives	64
	2.3. Identification des variables de qualité de l'eau par l'ACP	67
	2.4. Matrice de corrélation	68
	3. Application de la technique de Gamma test (GT)	69
	4. Conclusion	70
Chapitre VI :	Méthode de surface de réponse (RSM)	
	1. Introduction	71
	2. Matériel et méthodes	71
	3. Résultats et discussion	73
	3.1. Analyse de la variance (ANOVA)	73
	3.2. Optimisation des réponses numériques	86
	4. Conclusion	87
Chapitre VII :	Application des réseaux de neurones artificiels à la prévision de l'indice de qualité de l'eau	
	1.Introduction	88
	2. Matériel et méthodes	88
	2.1. Processus de modélisation par ANN	88
	3. Résultats et discussions	90
	4. Comparaison des modèles ANN et RSM	98
	5. Performances des modèles	100
	6. Conclusion	101
	Conclusion générale	102
	Références bibliographiques	

Introduction générale

Introduction générale

Au fil des dernières décennies, le développement démographique, l'urbanisation et l'industrialisation ont connu une expansion mondiale, ils ont causé de graves problèmes environnementaux, principalement dus aux rejets d'effluents liquides dégradant les propriétés de l'eau douce nécessaire aux êtres vivants et à l'industrie (Nguyen and Huynh 2022). En effet, la pollution de l'eau peut indirectement causer des maladies épidémiologiques et parasitaires, ainsi que la diminution de biodiversité. Par conséquent, il est devenu un défi majeur pour de nombreux pays en développement de gérer et de suivre la longévité de ces ressources (Aazami et al., 2015 ; Javed et al., 2017 ; Uddin et al., 2018). Cependant, ces pays peuvent évaluer, prédire et contrôler la contamination de cette eau par la surveillance de ses caractéristiques physico-chimiques, qui sont le principal indicateur spatio-temporel de la qualité de l'eau (Zaghloul et al. 2023), afin de fournir une base pour planifier l'utilisation durable de cette ressource importante (Mama et al. 2021). Pour y parvenir, différentes méthodologies sont utilisées, incluant l'indice de qualité de l'eau (WQI) (Calmuc et al., 2020 ; Fonge et al., 2013 ; Georgescu et al., 2023 ; Gharib et al., 2011; Kouadri et al., 2021; Zhang et al., 2020).

Il est important de collecter d'importantes quantités de données sur divers paramètres car il n'existe pas de facteurs universels pouvant déterminer la qualité de l'eau. Le problème majeur demeure dans l'impossibilité d'utiliser un seul critère pour traiter ces données. Dans ce contexte, l'indice de qualité de l'eau (WQI) est devenu une mesure très efficace de la qualité de l'eau, fournissant des informations statistiques précieuses pour aider les décideurs dans leurs évaluations. L'un des avantages de cet indice réside dans la possibilité d'évaluer la qualité de l'eau sans avoir à déterminer séparément sa composition chimique. Grâce à leur simplicité d'utilisation basée sur des fondements scientifiques et dans le contexte de nouvelles études, de nombreux chercheurs ont utilisé divers indices de qualité pour évaluer la qualité de l'eau. WQI joue un rôle important dans la gestion des données afin d'évaluer et de suivre la qualité globale de l'eau pour un site spécifique, il combine différents paramètres de qualité de l'eau en une seule mesure sans dimension pouvant aller respectivement de 0 à 100, ou d'excellente à très mauvaise qualité (Akkaraboyina & Raju, 2012 ; Ramakrishnaiah et al., 2009). Cela permet aux gestionnaires d'évaluer et de comprendre plus facilement les niveaux de qualité de l'eau.

Il demeure un défi majeur pour prévenir et contrôler la pollution de l'eau en identifiant les sources de pollution. Le rejet continu d'eaux usées industrielles constitue un facteur persistant et préoccupant de ce problème. Une prévision précise des évolutions de la qualité de l'eau constitue une étape importante vers une gestion efficace de la pollution de l'eau, car elle joue

un rôle essentiel dans la surveillance de l'environnement, la durabilité des écosystèmes et la protection de la santé humaine. Le contrôle et la prévision de la qualité de l'eau permettent une meilleure gestion des ressources hydriques et soutiennent le choix de méthodes efficaces d'assainissement et de protection de l'écosystème.

Étant donné la complexité des paramètres physicochimiques et leur caractère non linéaire, les nouvelles technologies d'intelligence artificielle (IA) permettent de modéliser de nombreux problèmes complexes en temps réel (Safeer et al. 2022). Certaines études (Ahamad et al. 2019) concernant les mesures de qualité de l'eau dans deux lacs tout en développant des modèles prédictifs pour prédire les niveaux de pollution de l'eau. Entre temps, (Sunayana et al. 2020) ont employé des réseaux de neurones artificiels (ANN) afin de simuler la qualité des eaux souterraines près des décharges sanitaires éliminant les déchets solides. Pour atteindre cet objectif et surmonter les limitations précédentes, des méthodes efficaces, robustes et avancées doivent être utilisées pour estimer cette qualité. Les données sur les propriétés de l'eau sont essentielles pour établir les normes de qualité de l'eau, définir les futures sources, gérer les défis environnementaux, choisir les investissements, et mettre en place des actions pratiques pour prévenir la pollution (Ongley 1996). Cependant, il est compliqué de recueillir des informations sur l'eau en raison des fluctuations imprévisibles de l'environnement, de la nature non linéaire et non stationnaire et de l'ambiguïté causée par les liens interdépendants et les perturbations anthropiques (Tiyasha, Tung, and Yaseen 2020). Par conséquent, l'identification et l'obtention de données de qualité sur l'eau deviennent des tâches laborieuses.

Par conséquent, pour affronter efficacement ces défis, des méthodes puissantes intégrant les modèles d'IA. (Wen and Vassiliadis, 1998) ont été les premiers à utiliser des modèles hybrides de l'intelligence artificielle et des statistiques pour améliorer le fonctionnement d'une usine d'épuration des effluents liquides (STEP). Plusieurs essais ont été menés pour utiliser l'intelligence artificielle considérant la STEP comme un modèle à boîte noire pour prédire la qualité des eaux usées dans le contexte de la gestion des stations d'épuration (Mokhtari et al., 2020 ; Newhart et al., 2020 ; Niu et al., 2020 ; Nourani et al., 2018 ; Picos-Benítez et al., 2017; Sharafati et al., 2020; Sundui et al., 2021; Xin et al., 2020; X. C. Nguyen et al., 2022 ;Yoo et al., 2008). En outre, deux modèles de prévision de WQI ont été créés à l'aide des ANN par (Kadam et al. 2019) avant et après la tempête dans le bassin de la rivière Shivganga en Inde. Les recherches de Khayet et al (2011) ont démontré que l'ANN avait de meilleures capacités de prédiction que la RSM lors de l'optimisation du phénomène d'osmose inverse dans la station de dessalement de l'eau de mer. De plus, Azrou et al (2022) ont examiné la précision de l'ANN et divers algorithmes de régression pour prédire WQI.

WQI est un outil essentiel pour les décideurs car, il facilite la gestion et l'utilisation d'une matrice de données contenant un historique sur les caractéristiques de l'eau. Cet indice protège les surfaces d'eau qui alimentent les eaux souterraines tout en garantissant la préservation de la santé publique et de l'écosystème en respectant les limites acceptables des différents paramètres (Yang et al., 2007).

Cette étude sert d'outil de contrôle et de surveillance pour évaluer l'efficacité du traitement des usines d'épuration des eaux noires afin d'assurer l'élimination efficace des polluants avant leur rejet dans l'oued Marhoum (Skikda, Algérie). L'objectif est de minimiser les impacts néfastes sur la biodiversité de l'environnement aquatique. Par ailleurs, cette étude contribue à une gestion responsable des eaux industrielles, en respectant les limites de rejet fixées par le gouvernement comme indiqué dans le Journal Officiel de la République Algérienne, qui définit les normes autorisées pour les paramètres de rejet des effluents liquides industriels (JORA 2006).

Le but de cette étude est également de préserver l'environnement et de promouvoir le développement durable en examinant l'importance du WQI dans l'évaluation de la qualité physicochimique de l'eau épurée provenant de la STEP du complexe de raffinage de pétrole (RA1/K). Ensuite, cette recherche introduit une approche innovante pour prédire WQI en utilisant l'analyse en composantes principales (ACP) et Gamma test (GT) permettant de réduire le nombre d'entrées et améliorer la stratégie de travail. La mesure du WQI est effectuée en utilisant différents paramètres physicochimiques tels que le pH, la température, la conductivité électrique, le phosphore total (PO_4^{-3}), la demande chimique en oxygène (DCO) et les hydrocarbures totaux (CxHy) collectés d'octobre 2020 à mars 2023.

L'une des véritables innovations actuelles dans la gestion des ressources en eau est l'utilisation des méthodes ANN et RSM. L'approche par méthode de surface de réponse (RSM) construit une base statistique solide en détectant les corrélations entre les facteurs de traitement et le WQI, contrairement aux réseaux de neurones artificiels (ANN), qui utilisent des algorithmes d'apprentissage automatique (machine Learning) pour trouver des modèles non linéaires complexes dans les données.

Pour satisfaire les demandes croissantes en matière de qualité de l'eau et de préservation et de durabilité environnementale, ces deux modèles fournissent une approche complète et innovante de l'optimisation du processus d'épuration des eaux usées (Arab et al. 2022).

A notre connaissance, le développement de modèles de prédiction de WQI pour les eaux usées des raffineries utilisant ANN et RSM est un domaine de recherche nouveau et inexploré et aucune enquête n'a été menée sur ce sujet particulier. De plus, dans ce domaine, cette méthode

proposée résultant du jumelage de ces deux approches ANN et RMS a donné lieu à des résultats bien supérieurs à ceux des études antérieures. L'aspect novateur de ce travail est l'utilisation des méthodologies RSM-BBD et ANN pour fournir un cadre statistique robuste pour l'évaluation de la qualité de l'eau dans des environnements industriels complexes. Cette étude va au-delà des efforts précédents en fournissant une compréhension plus avancée des variations saisonnières des indices de qualité de l'eau, améliorant ainsi la capacité à mettre en action des stratégies de gestion environnementale les eaux usées issues des complexes pétroliers.

En raison de la présence de certains hydrocarbures dans les rejets des usines de traitement des raffineries, l'approche par RSM a permis d'identifier les éléments clés influençant la qualité de l'eau et la prédiction de WQI. La meilleure architecture pour un modèle de prévision fiable de WQI est déterminée efficacement par l'algorithme de Levenberg-Marquardt (LM). Grâce à ces techniques, il est plus facile d'utiliser des indicateurs pour évaluer la qualité de l'eau. Les performances de chaque modèle ont été testé en utilisant le coefficient de détermination (R^2), l'erreur quadratique moyenne (MSE), la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne (MAE).

C'est dans cette optique que s'inscrit l'objectif de cette modeste thèse scindée en sept chapitres. Les trois premiers chapitres de ce travail sont dédiés à une synthèse approfondie de littérature. Tout d'abord, nous abordons les principes généraux de la pollution de l'eau, en examinant ses sources, ses conséquences et les principaux contaminants en jeu. Par la suite, nous explorons les techniques de purification des effluents liquides, en mettant en lumière les différentes approches disponibles pour traiter efficacement les rejets polluants. Finalement, nous analysons le rôle croissant de l'intelligence artificielle dans l'évaluation de la pollution de l'eau, en mettant en évidence l'application des réseaux de neurones artificiels (ANN).

Les quatre derniers chapitres seront consacrés à la mise en œuvre d'une approche pratique pour évaluer la qualité de l'eau. Tout d'abord, nous présentons la zone d'étude, en décrivant ses caractéristiques géographiques et environnementales pertinentes pour notre étude. Ensuite, nous détaillons l'identification des variables d'entrée à travers des techniques telles que l'Analyse en Composantes Principales (ACP) et la technique de Gamma test (GT), visant à sélectionner les paramètres les plus influents sur la qualité de l'eau. Par la suite, nous abordons la méthode de surface de réponse (RSM), qui permet de modéliser et d'optimiser les réponses en fonction des variables d'entrée identifiées précédemment. Finalement, nous explorons l'application des ANN à la prévision WQI, offrant ainsi une approche innovante pour prédire et surveiller les rejets de manière efficace et précise.

Une conclusion à la fin qui résumera nos principaux résultats en soulignant les résultats les plus pertinents et proposer des solutions innovantes pour évaluer la qualité de l'eau et sa gestion, en combinant les connaissances théoriques et les techniques expérimentales les plus avancées dans ce domaine.

Chapitre I : Généralité sur la pollution industrielle

1. Introduction

Les eaux usées industrielles, également connues sous le nom d'eaux usées de procédé, sont des eaux utilisées, traitées ou stockées dans des installations industrielles. Les produits chimiques, les résidus d'huile et de graisse et les contaminants biologiques tels que les bactéries et les virus peuvent y être présents. Tant qu'elles répondent à certaines exigences, elles peuvent être rejetées dans la nature.

Ce chapitre examine plus en détail les principales sources de la pollution industrielle et leurs effets sur l'écosystème. Ensuite, nous diffusons diverses grandeurs afin de surveiller la pollution de l'eau.

2. Sources et types de pollution industrielle

La pollution se caractérise par la présence anormale ou non naturelle de substances dans l'environnement, provoquant une détérioration de la vie humaine et des perturbations des écosystèmes naturels (Dumat et al., 2016).

Les activités industrielles engendrent une diversité de substances potentiellement nocives pour l'environnement, se présentant sous forme liquide, solide ou gazeuse. Les polluants liquides incluent les pluies acides, les déversements chimiques et les évacuations d'eaux usées. À l'inverse, les polluants solides proviennent du ruissellement des procédés industriels, de la pollution particulaire issue de l'utilisation du charbon et d'autres combustibles, ainsi que des émissions gazeuses provenant des centrales électriques au charbon. Quant aux gaz polluants, on compte des exemples tels que le benzène, le toluène et les chlorofluorocarbures (Hade, 2003).

Ainsi, en fonction de la nature du polluant, la pollution industrielle peut être répertoriée en trois classes (Crini et al., 2007) :

2.1. Pollution chimique

Cette forme de pollution englobe la pollution organique, caractérisée par une concentration élevée de matière organique. Cela entraîne une demande excessive en oxygène dissous, conduisant à l'asphyxie et à la mort de la vie aquatique. D'autre part, la pollution organique se manifeste par la présence d'hydrocarbures dans les marées noires, souvent liées aux rejets des navires, et provient également des activités d'extraction de pétrole et de la production de ses dérivés. Également générée par le rejet d'eaux usées renfermant des hydrocarbures, des produits de nettoyage et des métaux lourds. La contamination chimique provient essentiellement de la libération de minéraux dangereux dans l'environnement. Parmi ces substances nocives figurent

des composés tels que les nitrates, ammoniac, phosphates, et autres sels ainsi que les ions métalliques. La pollution minérale, qui fait partie intégrante de la pollution chimique, résulte de la présence de métaux lourds. Ces métaux lourds, classés par ordre décroissant de toxicité, incluent le mercure (Hg), le chrome (Cr), le titane (Ti), le cuivre (Cu), le cobalt (Co), le nickel (Ni), le plomb (Pb), et le zinc (Zn) (Bliefert & Perraud, 2007).

2.2. Pollution physique

Elle se manifeste lorsque la composition physique de l'environnement altéré est influencée par divers éléments. Elle englobe notamment la pollution mécanique, se manifestant par la présence de particules variées, telles que des substances grossières, du sable ou des matières en suspension (Chevalier et al., 2003).

En outre, l'échauffement artificiel de l'environnement par le biais de sources de chaleur techniques telles que les circuits de refroidissement, ainsi que certaines installations telles que les centrales thermiques, les centrales nucléaires, les raffineries de pétrole et les aciéries, génèrent une forme de pollution thermique. Cette pollution se produit à des températures d'environ (70 à 80) °C, lorsqu'elle entre en contact avec l'eau du milieu aquatique, provoquant un réchauffement de l'eau. Cela a des conséquences sur la solubilité de l'oxygène, entraînant la mortalité de certaines espèces et favorisant le développement d'autres, ce qui induit un déséquilibre écologique (Hill and Helz 1973 ; Ngô and Régent 2012) .

2.3. Pollution biologique

De nombreux micro-organismes pathogènes ont la capacité de proliférer dans diverses parties de l'environnement tels que l'atmosphère, le sol et l'eau. Parmi eux, ceux présents dans milieu aquatique, tels que les bactéries, les virus, les parasites et les champignons, peuvent restreindre son utilisation, générant ainsi ce que l'on nomme des contaminations bactériennes, virales ou parasitaires (Hartemann, 2004 ; Hounsounou et al., 2016 ; Schaechter et al., 1999).

3. Indicateurs d'évaluation de la qualité des rejets

Avant d'évaluer l'impact de leur rejet sur l'écosystème environnant, il est raisonnable de d'identifier la qualité physico-chimique des eaux usées. En général, ces paramètres physico-chimiques fournissent une méthode efficace pour estimer le degré de pollution des effluents car ils servent de référence pour les exigences d'autosurveillance (Genin et al., 2003 ; Koller, 2004; Morin-Crini et al., 2022).

Les industriels sont actuellement requis de surveiller leurs rejets et de se conformer aux normes établies dans le JORA (2006) définissant les valeurs limites des paramètres de rejets d'effluents liquides industriels (Annexe 1). Certains de ces paramètres comprennent :

3.1. Indicateurs généraux ou classiques

3.1.1. Potentiel d'hydrogène (pH)

Les eaux usées industrielles peuvent présenter des variations importantes de pH en raison des processus de production spécifiques et des substances chimiques utilisées dans les installations industrielles. Ces variations peuvent avoir des implications sur la toxicité des organismes aquatiques, la solubilité des métaux lourds et d'autres polluants, ainsi que sur les performances des processus de purification de l'eau (Tchobanoglous et al., 2014).

3.1.2. Température

La température en degrés Celsius est un paramètre général d'une importance capitale. Bien que la croissance de la plupart des nitrificateurs est optimale à une plage de température comprise entre 25 et 30 °C. Des variations de température peuvent entraver la dynamique microbienne responsable de la réduction de l'azote. En conséquence, l'épuration biologique est compromise, car de nombreux organismes ne disposent pas de mécanismes de thermorégulation. Cette diminution de l'activité vitale entraîne un ralentissement global des processus de traitement (Aubry et al., 2008 ; Foucard et al., 2019; Meinck et al., 1977; Rodier et al., 2009; Sachon, 1980).

3.1.3. Conductivité électrique (CE)

Cette méthode constitue une solution rapide et économique pour évaluer la force ionique d'une solution, car elle reflète son aptitude à conduire le courant électrique. Ainsi, elle renseigne sur la présence et la concentration des cations tels que Ca, K, Mg, ainsi que des anions comme les chlorures, les sulfates, les phosphates et les nitrates. La conductivité de la solution est directement proportionnelle à la quantité de sels dissous qu'elle contient. En effet, des

fluctuations de cette valeur peuvent impacter le processus de traitement biologique ainsi que la phase de décantation (Abai et al., 2014 ; Morin-Crini et al., 2017).

3.1.4. Oxygène dissous (OD)

Sa concentration dans les cours d'eau fluctue constamment, avec des niveaux minimums pendant la nuit, souvent observés avant l'aurore et maximums pendant la journée, dont la photosynthèse des macrophytes et des algues peut être le principal facteur à l'origine des fluctuations de l'oxygène pendant la journée. La température de l'eau a également une influence sur le taux d'aération et l'activité des microorganismes aquatiques. Lorsqu'elle augmente, la solubilité de l'oxygène diminue, entraînant une réduction de sa concentration. Cependant, cette situation peut être corrigée par la génération d'oxygène via la photosynthèse. Par ailleurs, la température a un impact sur la quantité d'oxygène consommée par les organismes pendant la journée, notamment en raison de l'impact des rayons solaires sur la température de l'eau (Livingstone, 1991 ; O'connor & Di Toro, 1970; Villeneuve et al., 2006).

3.2. Indicateurs globaux de pollution

La compréhension de ces paramètres globaux aide à évaluer les niveaux potentiels de pollution et de toxicité des ions présents dans les effluents, ce qui pourrait avoir un impact sur la qualité des espaces avoisinants (Abai et al., 2014 ; Aubry et al., 2008 ; Rodier et al., 2009).

3.2.1. Matières en suspension (MES)

Lorsqu'elles se trouvent dans les eaux usées industrielles, elles suscitent une préoccupation majeure à cause de leur éventuelle influence sur l'atmosphère aquatique. Ces particules, comprenant des solides organiques et inorganiques. Leur présence dans les effluents peut augmenter la turbidité de l'eau, perturbant ainsi les processus de photosynthèse et la biodiversité aquatique (Degrémont, 1972) . De plus, ces matières en suspension peuvent adsorber des polluants organiques et inorganiques, tels que les métaux lourds et les hydrocarbures, augmentant ainsi leur transport et leur potentiel de contamination dans les écosystèmes aquatiques (Marchand & Martin, 1985). Ainsi, assurer une gestion efficace des MES dans les eaux usées industrielles est crucial pour préserver la santé des écosystèmes récepteurs et maintenir une qualité d'eau acceptable (Cyr et al., 2015). Pratiquement, l'élimination des MES est accomplie avec un traitement primaire, cela implique une décantation et une filtration pour piéger les particules insolubles (Divet & Schulhof,

1980 ; Édouard, 2021). Selon JORA (2006), il est recommandé de ne pas dépasser une teneur maximale de 35 mg. L⁻¹.

3.2.2. Demande chimique en oxygène (DCO)

C'est un indicateur utilisé pour estimer la teneur d'oxygène requise pour l'oxydation des composés organiques présents dans l'eau (Rodier et al., 2009 ; Thomas & Mazas, 1986). Sa réduction dans les eaux usées est cruciale et est souvent réalisée par des traitements biologiques pour prévenir les impacts négatifs sur l'environnement récepteur. Des méthodes telles que les lagunes aérées, les systèmes d'oxydation à boues activées ou les bioréacteurs à membranes exploitent la réduction biologique des composés organiques. Ces processus peuvent être efficaces pour diminuer la charge organique et améliorer la qualité de l'eau avant son rejet (Baumont et al., 2014 ; Henze et al., 2006). La recommandation de JORA (2006) stipule que la teneur en DCO ne dépasse pas 120 mg. L⁻¹. Cela s'explique par le fait qu'une teneur équivalente ou supérieure à 120 mg d'oxygène par litre (mg O₂/l) indique une contamination notable provenant à la fois d'activités naturelles et anthropiques (Diab W, 2016).

3.2.3. Demande biologique en oxygène (DBO₅)

Elle est fréquemment employée pour évaluer la concentration d'oxygène indispensable à la dégradation biochimique des substances organiques présentes dans l'eau. Un suivi régulier de la DBO₅ au sein des installations de purification de l'eau est crucial pour estimer l'efficacité du processus de traitement et détecter d'éventuels problèmes ou déviations. De plus, la surveillance des paramètres opérationnels de la station d'épuration, tels que la concentration en oxygène dissous, le temps de séjour des boues (Strande et al., 2018) et le rapport carbone/azote, peut également favoriser une meilleure élimination de la DBO₅ (Striebig et al. 2022). La réduction de la DBO₅ est habituellement réalisée à travers des méthodes biologiques, telles que l'utilisation de systèmes d'oxydation à boues activées et de lits bactériens, qui exploitent l'activité métabolique des micro-organismes pour décomposer les matières organiques (Henze et al., 2006). Des méthodes physico-chimiques, telles que la coagulation-floculation, l'adsorption sur charbon actif et l'ozonation, peuvent être employées alternativement qui peuvent être combinées avec des procédés biologiques pour augmenter l'efficacité de l'élimination de la DBO₅ (Tchobanoglous et al., 2003). D'après les directives de JORA (2006), la limite maximale autorisée de DBO₅ est fixée à 30 mg/l.

3.2.4. Turbidité

Elle représente l'opacité de l'eau causée par la présence des MES. Toutefois, une meilleure efficacité du traitement de l'eau peut maintenir ce paramètre à des niveaux plus bas. En général, la turbidité provient de l'érosion et du lessivage du sol, ainsi que des particules provenant de la décomposition des matières animales et végétales (Hayzoun et al., 2015 ; Rodier et al., 2009).

3.2.5. Indice de biodégradabilité (I)

L'indice de biodégradabilité est un indicateur de la capacité des eaux usées à être décomposées ou oxydées par les micro-organismes impliqués dans le processus de purification biologique de l'eau. Il est déterminé en calculant le rapport entre la DCO et la DBO₅, offrant ainsi un aperçu de la biodégradabilité de la matière organique contenue dans un effluent (Rodier et al., 2009 ; Tampo et al., 2021). Les limites de cet indice pour les déchets industriels sont les suivantes :

$I < 3$: Effluent facilement biodégradable ;

$3 < I < 5$: Effluent moyennement biodégradable ;

$I > 5$: Effluent difficilement biodégradable.

Ainsi, l'efficacité du processus de purification biologique dépend étroitement du contrôle du niveau de pollution, tel que reflété par cet indice, lequel est influencé par la nature et l'origine des eaux usées, qu'elles soient domestiques ou industrielles, nécessitant ainsi différents traitements (Tchobanoglous et al., 2014).

3.2.6. Métaux lourds

Les métaux lourds, tels que l'arsenic, le plomb, le cadmium, le chrome, le mercure, le nickel et dans une moindre mesure le cuivre, le zinc, le fer et l'aluminium, sont des polluants persistants dans l'environnement. En effet, selon Vilaginès & Vilaginès (2000), certains de ces métaux, notamment le cadmium, le mercure et le plomb sont absents dans les organismes vivants et ne remplissent aucune fonction nutritionnelle ou biochimique dans les microorganismes, les plantes ou les animaux (Von Sperling, 2007) .

Cependant, au-delà d'un certain seuil, tous les métaux lourds peuvent avoir un impact néfaste sur l'environnement. Ils ont l'aptitude de s'assembler dans les organismes sans être métabolisés, contaminant ainsi la chaîne alimentaire et provoquant des effets cancérogènes chez l'homme, tout en affectant la moelle osseuse, le système nerveux et le sang (Larrose, 2011; Von Sperling, 2007).

Les origines de ces éléments peuvent être rassemblées en deux grandes divisions principales : les sources naturelles ou brutes, telles que les éruptions volcaniques, les altérations rocheuses, et les sources anthropiques, notamment l'industrie métallurgique, l'exploitation minière, l'agriculture et les activités urbaines (Callender, 2003 ; Coynel et al., 2009; Devez et al., 2005; Sukandar et al., 2006). Pour traiter efficacement les métaux lourds, la méthode la plus appropriée consiste à former des floccs pour faciliter leur précipitation, souvent réalisée à l'aide de chaux (hydroxyde de calcium), ce qui permet de les transformer d'un état soluble à un état solide (Xu, 2015).

Conformément aux directives de JORA (2006), les concentrations requises pour le rejet des effluents liquides sont les suivantes : plomb (0,5 mg/l), mercure (0,01 mg/l), cadmium (0,2 mg/l), nickel (0,5 mg/l), chrome (0,5 mg/l), cuivre (0,5 mg/l), zinc (3 mg/l), fer (3 mg/l) et aluminium (3 mg/l).

3.3. Indicateurs complémentaires

3.3.1. Hydrocarbures

Les hydrocarbures constituent une part intégrante de notre vie quotidienne et, en raison de leur origine variée, ils sont présents dans l'environnement, qu'il soit naturel ou anthropique. Ce sont des composés organiques composés d'hydrogène et de carbone, parmi lesquels le méthane (CH_4) représente la forme la plus simple, constituant ainsi le principal composant du gaz naturel, tandis que les formes les plus complexes sont présentes dans le pétrole brut et les schistes bitumineux. En effet, les hydrocarbures représentent généralement de 65% à 95% de la composition de la plupart des pétroles bruts, se répartissant en quatre catégories principales : les hydrocarbures saturés (30% à 70%), les hydrocarbures aromatiques et polyaromatiques (20% à 40%), les composés polaires (5% à 25%), et le bitume (0% à 10%) (Commendatore & Esteves, 2004 ; Soltani, 2005; Vandecasteele & Ourisson, 2005; Volkman et al., 1992).

Il est cependant essentiel de noter que, selon les directives de JORA (2006), la concentration d'hydrocarbures dans les rejets d'eaux usées industrielles doit être maintenue en dessous ou égale à 10 mg/l.

3.3.2. L'Azote (N)

Dans l'écosystème aquatique, l'azote peut se présenter sous différentes formes, notamment l'azote ammoniacal ($\text{NH}_3\text{-N}$), les nitrites ($\text{NO}_2\text{-N}$) et les nitrates ($\text{NO}_3\text{-N}$). Principalement, l'azote ammoniacal provient de la dégradation des matières organiques présentes dans les eaux usées et se trouve généralement sous forme d'ammonium (NH_4^+), qui peut être converti en

nitrate par des bactéries nitrifiantes dans les systèmes de traitement biologique. Les nitrates et les nitrites, quant à eux, résultent de la nitrification de l'azote ammoniacal, les nitrates étant la forme d'azote la plus courante dans l'eau (Bollon et al., 2016 ; Couture, 2006 ; Rejsek, 2002). Des niveaux excessifs des nitrates endommagent la vie humaine et peuvent stimuler la prolifération d'algues et des plantes favorisant le phénomène de l'eutrophisation perturbant ainsi le développement de la vie aquatique, notamment la contamination des eaux souterraines. Le lessivage des terres agricoles ainsi que les rejets urbains et industriels sont les principales causes des fortes concentrations de nitrates (Banas & Lata, 2006 ; Templeton & Butler, 2011). La concentration d'azote dans l'eau issue des stations d'épuration des eaux usées dépendra du niveau de traitement des eaux usées ainsi que des procédés utilisés pour réduire la charge d'azote. Des méthodes de traitement supplémentaires, telles que la dénitrification, peuvent être mises en place pour réduire la concentration d'azote dans l'eau traitée (Bollon et al., 2016 ; Couture, 2006 ; Rejsek, 2002). Les différentes formes d'azote mentionnées constituent ce que l'on appelle l'azote global (NGL), dont la concentration maximale autorisée dans les effluents liquides industriels est de 30 mg/l (JORA, 2006).

3.3.3. Phosphore (PO_4)

L'origine du phosphore dans les eaux usées est déduite de la connaissance des sources naturelles de phosphore ainsi que de son utilisation. Il est présent sous forme de composés organiques et de sels minéraux (Ortho phosphates et poly phosphates). Il provient de diverses sources, notamment du métabolisme humain, où un individu excrète entre un et deux grammes de phosphore par jour, constituant ainsi la principale contribution de phosphore aux cours d'eau. Il provient également des produits ménagers avec une teneur en phosphore estimée à un à deux grammes par jour et par habitant. Les rejets industriels représentent une autre source significative de phosphore, transportant une quantité de composés phosphorés presque équivalente à celle des eaux usées domestiques, dans les régions relativement urbanisées. En revanche, les rejets agricoles ou d'origine naturelle sont retenus dans les sols et ne se retrouvent pas dans les eaux usées. Les eaux de surface peuvent éventuellement contenir du phosphore en raison de l'érosion et du ruissellement, entraînant des particules de sol dans les cours d'eau (Dernat & Pouillot, 1994 ; Deronzier & Choubert, 2004; Salomon, 2003; Villebrun, 1989).

La libération de phosphore dans les milieux aquatiques représente l'un des problèmes environnementaux les plus sérieux car elle contribue à accélérer le processus d'eutrophisation (Banas & Lata, 2006). Selon Sawadogo (2018), l'élimination du phosphore dans les eaux usées par traitement primaire et secondaire est estimée entre 10 et 30%. En revanche, le traitement

biologique, par le biais de l'absorption cellulaire de luxe, améliore cette élimination grâce à l'action de microorganismes spéciaux appelés organismes accumulateurs de phosphore (OAP), capables d'absorber environ 7 à 8 % du phosphore (Templeton et Butler, 2011 ; Comeau et al., 1986 ; Deronzier & Choubert, 2004).

De plus, lorsque la concentration en phosphore dépasse 0,5 mg/l, cela indique un indice de pollution et peut entraîner la dystrophisation de l'environnement récepteur (Rodier et al., 2009). Selon les directives de JORA (2006), la concentration maximale autorisée de phosphore dans les rejets d'effluents liquides industriels ne doit pas dépasser 10 mg/l.

3.3.4. Sodium (Na)

Le sodium provient de l'utilisation de produits désinfectants comme l'hypochlorite de sodium et la soude caustique, qui sont largement disponibles, faciles à utiliser et peu coûteux. Lorsqu'il est présent dans rejets d'eau usée, le sodium peut altérer la structure du sol, entraînant une diminution de la capacité de rétention d'eau (Sawadogo, 2018 ; Sou et al., 2013). Pour éliminer le sodium des eaux, divers procédés sont utilisés, tels que l'électrodialyse, la filtration sur membranes (osmose inverse ou nanofiltration), la distillation ou la déionisation sur résines échangeuses d'ions (Imran et al., 2016).

4. Notion de risque lié à l'eau usée

La mauvaise qualité de l'eau est responsable de nombreuses maladies à travers le monde, en particulier dans les pays en développement, où 80 % des maladies sont attribuées à l'eau (Adjagodo et al., 2017 ; Sy et al., 2017).

Sans traitement, les eaux usées dans les milieux aquatiques peuvent causer des dommages irréversibles à la santé humaine et aux écosystèmes et. Selon Prost & Boutin (1989), il existe trois catégories distinctes de niveaux de risque. Le premier est le risque théorique d'infection, qui est évalué en fonction de la présence ou de l'absence de microorganismes pathogènes dans le milieu étudié. Le second est le risque expérimental, dans lequel les agents pathogènes doivent être présents dans l'environnement à une concentration équivalente à la dose infectante et survivre dans une quantité suffisante (Feachem et al., 1983). Le troisième est le risque réel, également appelé risque attribuable, que l'épidémiologiste observe dans une population exposée. Il diffère du risque expérimental en introduisant les facteurs environnementaux physiques et sociaux susceptibles de modifier l'exposition des personnes au risque. Le risque attribuable est représenté par le nombre de cas d'infections supplémentaires signalés dans une communauté utilisant les eaux usées par rapport à l'époque où les eaux usées n'étaient pas

recouvertes montre le risque associé (Blum & Feachem, 1985 ; Melloul & Hassani, 1999). Selon l'UNICEF, 60 % de la mortalité infantile mondiale est due à des maladies infectieuses ou parasitaires, principalement liées à la pollution de l'eau (Rouamba et al., 2016 ; Some et al., 2014).

5. Conclusion

Pour la vie quotidienne, le traitement de l'eau revêt une importance capitale pour protéger à la fois les écosystèmes aquatiques et la santé humaine contre les maladies infectieuses potentiellement dévastatrices. Cependant, la contamination de cette ressource précieuse par des agents pathogènes et des substances toxiques constitue une menace sérieuse, c'est pourquoi le traitement de l'eau est devenu de plus en plus crucial.

Chapitre II : Techniques d'épuration des eaux usées

1. Introduction

Les effluents provenant des activités anthropiques, industrielles et agricoles, contiennent souvent une variété de polluants et de substances nocives qui nécessitent une élimination efficace avant d'être rejetées dans l'environnement naturel ou réutilisées à des fins diverses. Dans ce chapitre, nous explorerons les diverses méthodes utilisées pour purifier les eaux usées, un processus essentiel pour maintenir l'équilibre des écosystèmes aquatiques et protéger la santé publique.

2. Procédés d'épuration des eaux usées

Les systèmes et installations d'épuration des effluents liquides sont conçus pour éliminer efficacement ces polluants et rendre les eaux usées sûres pour l'environnement et les êtres vivants. Ces installations comprennent généralement plusieurs étapes de traitement, telles que le prétraitement, le traitement biologique, le traitement chimique et la désinfection. Chaque étape vise à éliminer spécifiquement certains polluants, en utilisant des processus physiques, chimiques et biologiques.

2.1. Procédés physico-chimiques

On utilise fréquemment les techniques de traitement physico-chimique dans le secteur du traitement des eaux usées industrielles. Parmi ces méthodes, on retrouve notamment (Sawadogo 2018):

- La phase de coagulation-floculation qui vise à agréger les matières en suspension (MES) et les colloïdes en formant des floccs, qui sont ensuite séparés à l'aide de systèmes de décantation, de flottation et/ou de filtration (Sawadogo 2018; Simate 2015; Verma, Dash, and Bhunia 2012; Zahrim, Tizaoui, and Hilal 2011). Le terme "colloïde" tire son origine des mots grecs "kolla", signifiant colle, et "eido", signifiant comme (Graham 1861). Ces réactions d'échange sont influencées par divers paramètres tels que la valence, le degré d'hydratation et le rayon ionique des ions échangés (Sridharan and Jayadeva 1980).

Le charbon actif est un matériau poreux à base de carbone, doté d'une surface spécifique très élevée, ce qui lui permet d'adsorber efficacement les impuretés présentes dans les liquides et les gaz (Sawadogo 2018). Le charbon actif, selon Jaiyeola & Bwapwa (2016), est l'un des adsorbants les plus efficaces pour éliminer une grande variété de contaminants issus des effluents industriels. En outre, des chercheurs ont obtenu un taux de réduction de 96 % de la

DCO en employant du charbon actif issu de cornes d'animaux pour l'épuration des eaux usées industrielles (Emmanuel & Olalekan, 2008 ; Sawadogo, 2018) .

Les techniques de filtration sur membrane sont également utilisées dans le traitement des eaux usées (Braeken et al., 2004 ; Ince et al., 2000; Sawadogo, 2018). Elles interviennent généralement lors d'une étape de post-traitement pour améliorer la qualité des eaux traitées, notamment en vue de leur réutilisation (Jaiyeola and Bwapwa 2016; Sawadogo 2018). Par exemple, la nanofiltration et l'osmose inverse ont été employées pour éliminer les sels des effluents traités (Qin et al. 2017; Sawadogo 2018).

Cependant, ces méthodes rencontrent souvent des limites en termes de performances, ne permettant pas toujours d'atteindre les niveaux d'abattement de charges polluantes requis par la réglementation en vigueur (Simate et al. 2011).

2.2 Procédés biologiques

Les méthodes de purification biologiques utilisant des microorganismes pour décomposer la matière organique des effluents industriels semblent généralement être plus efficaces que les méthodes physico-chimiques. Pour stimuler leur croissance et leur reproduction, ces microorganismes éliminent à la fois la pollution organique carbonée biodégradable ainsi que la pollution inorganique (Menoret 2001; Sawadogo 2018). Ils sécrètent des enzymes dans le milieu, qui déclenchent des réactions chimiques et biochimiques (Koné 2011). Cela provoque une dégradation biologique ou physico-chimique en utilisant le carbone, le fer, l'azote, le soufre, et d'autres ions. Les enzymes intracellulaires sont impliquées dans l'assimilation des métabolites, tandis que les enzymes extracellulaires dégradent les structures moléculaires complexes pour les rendre assimilables par les bactéries. Les performances des processus biologiques dépendent de l'utilisation dynamique du substrat et de la croissance microbienne. Comprendre ces réactions biologiques et les principes de base régissant la croissance des microorganismes permet une exploitation efficace du procédé (Bolmstedt, 2000 ; Sawadogo, 2018; Templeton & Butler, 2011).

Jaiyeola & Bwapwa (2016) ainsi que Simate et al. (2011) soutiennent que les procédés biologiques sont plus viables que les procédés physico-chimiques en raison de leur efficacité élevée dans l'élimination de la DCO (environ 80-90% d'élimination), de leur coût d'investissement maîtrisé et de leur maturité technologique. Cependant, ces techniques présentent des inconvénients tels que leur adaptation limitée aux variations brutales et importantes des charges polluantes. Par exemple, les boues activées et le lagunage sont

sensibles aux baisses de température des effluents, ce qui ralentit les processus biologiques. De plus, les investissements peuvent être importants car les stations doivent être dimensionnées pour traiter la pollution maximale, qui survient seulement quelques fois par an. En réalité, il existe différentes méthodes biologiques pour traiter les effluents, y compris le traitement aérobie (avec l'utilisation d'oxygène naturel ou artificiel) et le traitement anaérobie (sans l'utilisation d'oxygène).

2.2.1. Epuration biologique aérobie

Le processus est considéré comme aérobie lorsque l'oxydation de la matière nécessite la présence d'oxygène dissous, ce qui conduit à la formation de dioxyde de carbone (CO₂) et d'eau (H₂O) (Sawadogo 2018). Ce mode de traitement est recommandé pour les effluents à faible charge, c'est-à-dire ceux ayant une concentration en DCO biodégradable inférieure à 1 g/L (Chan et al. 2009; Sawadogo 2018). Dans ce contexte, la dégradation biologique est exothermique. En outre, cette méthode est plus rapide et plus complète, ce qui en fait généralement le choix privilégié dans les procédés de traitement des eaux usées, tout en favorisant une plus grande production de biomasse cellulaire (Driessen and Vereijken 2003; Sawadogo 2018).

Les bioréacteurs aérobies sont généralement groupés en deux catégories principales : les cultures fixées et les systèmes de croissance en suspension. Bloor et al. (1995) ont utilisé un réacteur aérobie pour traiter les eaux usées d'une brasserie, atteignant une élimination de DCO d'environ 97 % sur une période de 37 jours, avec une charge initiale de DCO de 50 kg/m³.jour (Sawadogo 2018). Bien que les lagunes naturelles aérées soient faciles à exploiter, elles nécessitent un long temps de rétention de l'eau, ce qui implique un volume de bassin considérable (Namèche and Vassel 1999). Selon (Driessen and Vereijken 2003), l'espace exigé a limité l'utilisation de cette technologie dans le traitement des eaux usées industrielles (Sawadogo 2018). L'utilisation d'un lit planté de *Typha Capensis* et *P. Australis* en bloc séquentiel pour traiter les eaux usées de la brasserie a été examinée dans des travaux de recherche, tels que ceux de (Crous and Britz 2010; Sawadogo 2018). Ce système, utilisé après un réacteur anaérobie et un chenal algal, a permis d'obtenir des eaux traitées répondant aux normes de rejet en vigueur en République Sud-Africaine, avec des rendements d'élimination respectifs de 33 % pour les orthophosphates, de 20% pour la DCO et de 86 % pour les nitrates (Sawadogo 2018).

2.2.2 Epuration biologique anaérobie

Lorsque le transfert d'hydrogène se produit et que l'accepteur final de l'hydrogène n'est pas le dioxygène, le processus est considéré comme anaérobie. D'autres produits sont générés en fonction du substrat dégradé, en plus du méthane (CH_4), qui est le composé le prédominant du processus anaérobie, du dioxyde de carbone (CO_2) et du dihydrogène (H_2). Ces substances comprennent l'hydrogène sulfuré (H_2S), qui est issu des sulfates (SO_4^{2-}) ou du soufre organique, et l'ammonium (NH_4^+), qui provient des protéines de la biomasse (Prieur 2014; Sawadogo 2018). Le phénomène de digestion anaérobie des polluants organiques se déroule en quatre étapes principales :

a. L'hydrolyse

L'hydrolyse est l'étape unique qui se déroule en dehors de la cellule. Dans cette étape, les bactéries hydrolytiques décomposent les molécules organiques de poids moléculaire élevé que les glucides, les lipides et les protéines en monomères de masse molaire réduite telles que les sucres simples, les acides gras à longue chaîne et les acides aminés (Sawadogo 2018).

b. Fermentation (l'acidogènes)

La phase de fermentation, également connue sous le nom d'acidogènes, représente une étape importante où les bactéries acidogènes transforment les produits hydrolysés en une gamme d'acides gras volatils tels que l'acide butyrique, l'acide propionique et l'acide acétique. De plus, cette transformation engendre la formation de composés neutres tels que l'ammonium, ainsi que des résultats gazeux tels que le CO_2 , le dihydrogène (H_2) et l'éthanol. En conséquence, le milieu réactionnel devient acidifié, jouant un rôle crucial dans la régulation de l'environnement chimique nécessaire à la progression efficace du processus de digestion anaérobie (Sawadogo 2018).

c. L'acétogenèse des acides gras

La phase d'acétogenèse des acides gras représente une étape cruciale où les produits résultant de l'hydrolyse et de la fermentation sont métamorphosés en acétate, CO_2 et H_2 grâce à l'action des bactéries acétogènes. Au cours de ce processus, les acétogènes décomposent les substrats organiques en acétate, qui est ensuite utilisé comme source d'énergie pour les étapes suivantes de la digestion anaérobie. En même temps, du CO_2 et du H_2 sont libérés, contribuant à

l'équilibre chimique et énergétique de la réaction. Cette conversion est essentielle pour la production de métabolites intermédiaires qui seront ensuite utilisés dans les phases ultérieures du processus de digestion anaérobie (Sawadogo 2018).

d. Méthanogenèse

La méthanogenèse représente la phase finale et essentielle du processus de digestion anaérobie, au cours de laquelle les microorganismes méthanogènes convertissent les produits intermédiaires de la fermentation en biogaz. Ce biogaz est principalement composé de CO₂ et de méthane (CH₄), avec le méthane comme composant prédominant (Sawadogo 2018). Cette transformation est cruciale car elle permet d'utiliser l'énergie chimique stockée dans les composés organiques dégradés tout au long du processus de digestion anaérobie. Le méthane ainsi produit est utilisé comme source d'énergie renouvelable, tandis que le CO₂ est souvent recyclé dans le processus. Cette phase finale représente donc un aboutissement du processus, transformant les déchets organiques en une source d'énergie utile, tout en réduisant l'impact environnemental des déchets organiques en les transformant en une ressource précieuse.

2.2.3 Epuration biologique combinée aérobie-anaérobie

L'idée de les combiner a été envisagée pour tirer parti des avantages des processus aérobie et anaérobie. Selon Chan et al. (2009), l'intégration des deux processus dans le traitement des eaux usées industrielles est bénéfique pour une élimination efficace de la demande chimique en oxygène (Sawadogo 2018). Il a également été démontré que l'utilisation de ces processus combinés peut réduire les coûts opérationnels par rapport à l'utilisation d'un système aérobie seul tout en réduisant l'excès de boue en phase aérobie (Vera et al. 1999).

2.2.3.1. Avantages de l'épuration biologique combinée

Selon les travaux de Cervantes et al. (2006), les avantages de cette combinaison incluent (Sawadogo 2018):

- Le processus de prétraitement anaérobie démontre clairement le potentiel considérable de récupération des ressources. Cette méthode innovante est essentielle pour éliminer efficacement la plupart des polluants organiques des déchets tout en les transformant en biogaz. Le biogaz, qui est généré à partir des déchets organiques tels que les déchets alimentaires ou agricoles, présente un double avantage : il permet de valoriser ces déchets qui pourraient autrement être nuisibles tout en générant une source d'énergie renouvelable et propre. En plus

de diminuer l'impact carbone, contribuant ainsi à la durabilité énergétique et environnementale à long terme.

- Le processus de traitement est remarquable à plusieurs égards. Le post-traitement aérobie est une étape importante dans l'évolution des effluents provenant du système anaérobie. Grâce à ses capacités avancées de purification, ce processus améliore la qualité globale de l'effluent en combinant judicieusement les deux techniques, pour répondre pour satisfaire aux normes strictes de qualité de l'eau.

- Un aspect notable du prétraitement anaérobie est la réduction significative de la consommation d'énergie. Ce processus innovant réduit la demande quotidienne d'oxygène, ce qui augmente l'utilisation des ressources énergétiques. Le prétraitement anaérobie permet une réduction supplémentaire de la capacité d'aération maximale requise dans le processus d'épuration des eaux usées (Sawadogo 2018).

- Le processus anaérobie est essentiel dans la décomposition des composés organiques volatils contenus dans les effluents résiduels, ce qui réduit leur potentiel de volatilisation lors du traitement aérobie ultérieur (Sawadogo 2018). Cependant, malgré ses avantages, l'approche combinée anaérobie-aérobie traditionnelle présente certains inconvénients notables. Parmi ceux-ci, on peut citer la nécessité d'utiliser des surfaces plus grandes pour les installations, la production excessive de boues et une consommation d'énergie supplémentaire nécessaire pour les processus de recirculation et d'aération (Chan et al. 2009; Sawadogo 2018).

2.3. Procédés d'oxydation avancée (POA)

Les procédés d'oxydation avancée (POA) représentent des méthodes de traitement physico-chimique visant à dégrader les polluants organiques en utilisant des réactions spécifiques pour générer des radicaux libres (Zaviska et al., 2009). Ces radicaux libres, tels que les OH, sont extrêmement réactifs et capables d'interagir avec une variété de composés organiques réfractaires (Jaiyeola and Bwapwa 2016; Zaviska et al. 2009). Ces procédés impliquent des réactions homogènes et sont hautement respectueux de l'environnement, ce qui en fait des technologies émergentes avec un potentiel considérable pour éliminer les polluants présents dans divers types d'eaux usées, y compris les effluents des industries de production de boissons (Sawadogo 2018).

Les performances prometteuses des POA ont été démontrées dans plusieurs projets de dépollution d'effluents résiduels. Par exemple, dans une étude menée par Lucas et al., (2010) sur le traitement des eaux usées d'une industrie vinicole, l'utilisation des procédés d'oxydation

avancée, notamment l'ozone, a permis une élimination efficace de la demande chimique en oxygène (DCO) et du carbone organique total (COT).

2.4. Procédés électrochimiques

En raison de leur efficacité dans l'élimination des chlorures et des substances organiques réfractaires, les techniques électrochimiques sont devenues une option privilégiée pour l'épuration des effluents industriels (Barrera-Díaz et al., 2009 ; Vijayaraghavan et al., 2006). Ces techniques offrent la possibilité de dégrader totalement ou partiellement les composés organiques difficiles à traiter présents dans les échantillons d'eaux usées.

Pendant le processus d'électrolyse, les composés organiques présents dans les eaux usées génèrent du chlore, qui est ensuite converti en acide hypochloreux. Ce dernier agit comme agent oxydant, facilitant l'oxydation des composés organiques. Par exemple, dans une étude menée par Vijayaraghavan et al. (2006), l'acide hypochloreux produit par les chlorures a été utilisé avec succès pour dégrader la pollution organique dans les effluents de brasserie, entraînant une réduction significative de la DCO, atteignant jusqu'à 94%.

Dans une perspective plus générale, selon Sawadogo, (2018), le traitement des eaux usées issues de l'industrie de production de jus de fruits en utilisant des méthodes telles que l'électrooxydation, l'électrocoagulation et l'électro-Fenton où les résultats ont montré des taux d'élimination de la DCO de 52% après 60 minutes et 65% après 360 minutes pour l'électrooxydation, ainsi que des pourcentages respectifs de 59% et 61% pour l'électrocoagulation avec des électrodes d'anode en aluminium et en fer. En outre, l'électro-Fenton, combiné à l'ajout de peroxyde d'hydrogène, a permis d'atteindre un taux impressionnant de 84% d'élimination de la DCO après seulement 25 minutes (Sawadogo 2018).

2.5. Technologies membranaires

Grâce à sa capacité à générer de l'eau de qualité supérieure de manière stable et à un coût relativement abordable, la technologie de l'osmose inverse (OI) est devenue de plus en plus répandue dans le traitement et la réutilisation de l'eau au cours des trois dernières décennies, en réponse aux pénuries d'eau rencontrées dans de nombreuses régions (Joo & Tansel, 2015 ; Zhou et al., 2011). Cependant, un inconvénient majeur de cette méthode est la production simultanée d'un flux de concentré d'osmose inverse (COI), représentant généralement entre 5 et 25 % du flux d'alimentation. Ce concentré est également caractérisé par une concentration de 4 à 20 fois supérieure à celle de l'eau d'alimentation, ce qui en fait un défi pour la

récupération des eaux usées industrielles et urbaine (Shanmuganathan et al. 2017). Le flux de concentré d'osmose inverse peut présenter des concentrations élevées de composés organiques et inorganiques récalcitrants, comprenant des matières organiques naturelles, des micropolluants organiques (Meerganz von Medeazza, 2005 ; Mohamed et al., 2005; Pérez et al., 2010), des métaux lourds nuisibles (Tran et al. 2012) et des additifs chimiques (Dialynas, Mantzavinos, and Diamadopoulos 2008). Le rejet direct du COI dans l'environnement sans traitement approprié constitue un risque écotoxicologique et un impact environnemental sérieux. Par conséquent, l'élimination efficace du COI représente le principal défi à relever pour garantir une utilisation durable de la technologie d'osmose inverse (Bagastyo et al. 2013).

3. Conclusion

Dans le cadre de la préservation durable des ressources en eau, le traitement des eaux usées joue un rôle crucial pour garantir la disponibilité d'une eau nette et sûre pour les usages domestiques, industriels et agricoles. Les techniques de purification des effluents liquides sont devenues de plus en plus sophistiquées, permettant de traiter de manière efficace une grande diversité de contaminants présents dans les eaux usées. Cependant, pour assurer l'efficacité et l'optimisation de ces techniques, il est essentiel d'avoir des dispositifs fiables et précis de surveillance de la qualité de l'eau traitée. C'est là qu'intervient la modélisation de la qualité de l'eau usée, qui offre une approche systématique et scientifique pour évaluer, prédire et optimiser les performances des stations de purification des eaux usées.

Chapitre III : L'intelligence artificielle au service de l'évaluation de la pollution de l'eau

1.Introduction

Il est temps de commencer à prendre soin de l'environnement pour équilibrer l'écosystème en raison de l'augmentation constante de l'industrialisation et de la population mondiale. De plus, les données expérimentales obtenues à partir de l'analyse environnementale sont généralement non linéaires et multivariées. Cela signifie que les protocoles analytiques traditionnels ne peuvent pas être utilisés pour prendre des mesures précises pour atteindre les objectifs d'une surveillance environnementale efficaces (Inobeme et al., 2022). Pour résoudre ce type de problème, il est nécessaire d'utiliser des modèles de l'intelligence artificielle tels que les réseaux de neurones artificiels (ANN) et les méthodes de surface de réponse (RSM).

2.Théorie des réseaux de neurones artificiels (ANN)

2.1. Historique des réseaux de neurones artificiels

Les modèles de réseaux de neurones artificiels (ANN) sont des programmes informatiques destinés à imiter les capacités de traitement de l'information humaine (Abdul-Wahab & Al-Alawi, 2002).

À la fin du XIXe siècle, le célèbre psychologue américain W. James a introduit le concept de mémoire associative en 1890 et a proposé la loi de fonctionnement de l'apprentissage des réseaux neuronaux, qui constituent aujourd'hui la loi de Hebb (James, 1984).

De plus, McCulloch (un neurophysiologiste) et Pitts (un logicien) ont créé en 1943 un système de réseau neuronal artificiel (ANN) similaire aux neurones biologiques, qui est le neurone formel (McCulloch & Pitts, 1990). En 1949, le physiologiste américain D. Hebb expliquait les réflexes conditionnés des animaux à travers les propriétés des neurones eux-mêmes. Ainsi, un conditionnement de type pavlovien, comme nourrir un chien à la même heure chaque jour, ferait saliver l'animal à ce moment précis même en l'absence de nourriture. Sa proposition de loi de modification des propriétés des connexions entre neurones explique en partie ces résultats expérimentaux (Hebb, 1949).

Par ailleurs, F. Rosenblatt a développé le modèle Perceptron en 1957, sur la base duquel il a construit le premier neurone artificiel et l'a appliqué au domaine de la reconnaissance de formes. Malgré les moyens restreints dont on disposait à l'époque, ils parvenaient à faire fonctionner cette machine de manière adéquate pendant des périodes excédant quelques minutes (Rosenblatt, 1958). Ce concept fut ensuite mis en réseau sur un cas réel pour la première fois, en 1959 par Bernard Widrow et Marcial Hoff qui ont développés le modèle ADALINE (ADAPtive LInear NEuron) avec une couche d'entrée et une couche de sortie pour

simuler le fonctionnement rétinien de reconnaître des formes basées sur l'algorithme de retro propagation de gradient très utilisé aujourd'hui avec les perceptrons multicouches (Kharroubi et al., 2016; Widrow & Hoff, 1960). Par la suite, Minsky et Papert ont publié un article en 1969 soulignant les limites théoriques du perceptron, à savoir l'incapacité d'utiliser le modèle pour traiter des problèmes non linéaires (Minsky & Papert, 1988).

Trois ans plus tard, en 1972, Kohonen présente ses recherches sur les mémoires associatives et suggère des méthodes pour la reconnaissance de formes (Kohonen, 2012).

Au début des années 80s et précisément en 1982, le physicien Hopfield présente la théorie des réseaux de neurones et leur potentiel (Hopfield, 1982). Par la suite, en 1983, la machine de Boltzmann devient le premier modèle reconnu capable de gérer de manière satisfaisante les contraintes rencontrées dans le domaine du perceptron. Cependant, sa mise en pratique est complexe en raison de son temps de calcul extrêmement long (Ackley et al., 1985). Deux ans plus tard, en 1985, apparaît le perceptron multicouche basé sur l'algorithme d'apprentissage par rétropropagation du gradient qui devient actuellement l'un des modèles les plus efficaces (Cornuéjols & Miclet, 2011).

2.2. Structure du neurone formel

Un ANN ou neurone formel est un modèle à boîte noire qui comprend un ensemble d'éléments de structures identiques appelées cellules (ou neurones) interconnectées comme celles du système nerveux humain (Coulbaly et al., 1999 ; Thamcharoen et al., 2020). À partir des neurones biologiques, des auteurs comme Werbos (1982) ont été inspirés pour développer des neurones formels ou artificiels (Werbos, 2005). Chaque neurone artificiel est un opérateur mathématique (une fonction algébrique) non linéaire, limitée, dont la valeur dépend de paramètres appelés poids ou coefficients (Dreyfus et al, 2002.). Il se caractérise par des paramètres, généralement appelés coefficients synaptiques qui stockent les informations et par une fonction dite d'activation (Touzet, 1992). Ce neurone peut avoir une ou plusieurs variables et une ou plusieurs sorties, Il est également constitué d'une série de couches reliées de manière à ce que chaque neurone reçoive l'entrée de la sortie du neurone précédent (Parizeau, 2004).

Par ailleurs, chaque réseau de neurones est doté de capacités de modélisation prédictive élevées, c'est-à-dire que toutes les caractéristiques décrivant des situations inconnues doivent être présentés au ANN entraîné, et l'identification (la prédiction) est alors donnée (Lek & Guegan, 1999 ; Olden & Jackson, 2001). La comparaison entre les éléments des neurones biologiques et les composants des neurones formels est illustrée dans la **Figure III.1**.

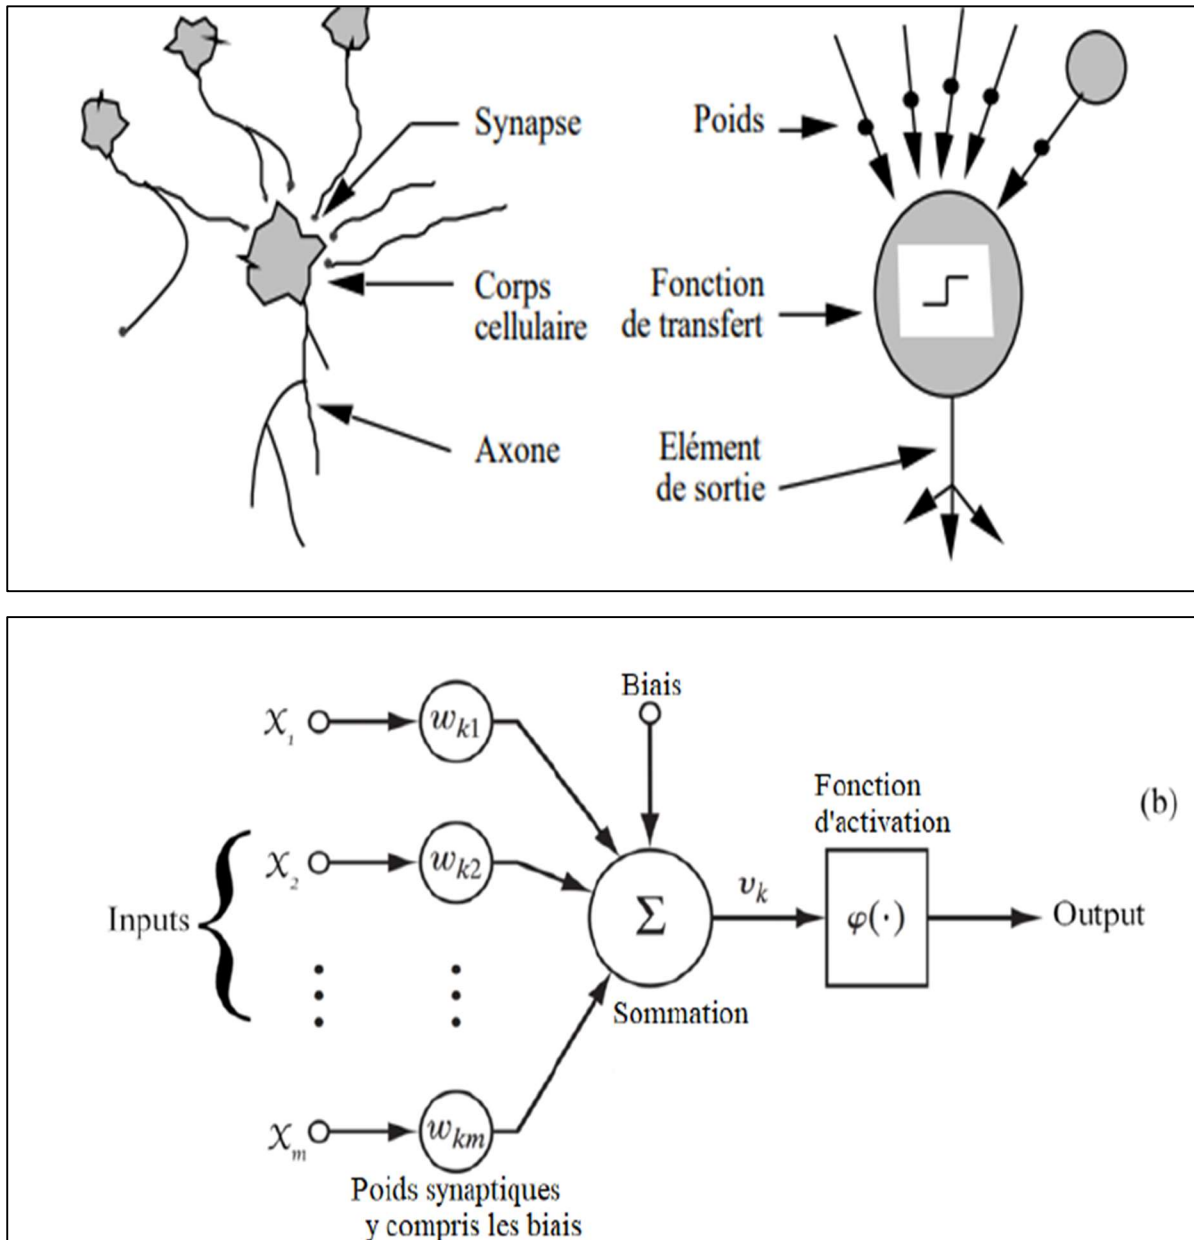


Figure III.1. Homologie entre le neurone biologique et le neurone formel
(Haykin, 2009; Touzet, 1992)

2.3. Réseaux de neurones artificiels à perceptron multicouches (MLPNN)

Pour la conception des ANN de prévision de la qualité de l'eau, le perceptron multicouche (MLP) est le modèle le plus utilisé ou appelé aussi modèle à plusieurs étages, adaptés à la résolution de différents types de problèmes (Le Cun, 2019). L'architecture du MLPN est déterminée par l'arrangement de plusieurs unités simples interconnectées, qui ressemblent à des neurones (Bouaoune & Dahmani-Megrerouche, 2010). Il comprend trois couches (Siddique & Adeli, 2013 ; Hébert, 2012) : une couche d'entrée qui reçoit l'information (variable explicative), une ou plusieurs couches cachées ou intermédiaires avec une fonction d'activation effectuant des calculs et une couche de sortie qui restitue l'information. Les neurones relient ces couches avec un poids et un biais, pondéré et biaisé (Najah et al., 2011). À l'aide d'une fonction d'activation (f), les variables pondérées sont additionnées avec le biais de la couche, qui est converti de la $n^{\text{ème}}$ couche à la $n^{\text{ème}+1}$ couche et ainsi de suite, jusqu'à la couche cible. La procédure d'apprentissage est effectuée de manière itérative, en ajustant les poids synaptiques des couches et les biais par une méthode d'optimisation jusqu'à l'obtention d'une excellente performance avec le meilleur coefficient de corrélation et la moindre MSE (Ghaemi et al., 2023 ; Hamzehie et al., 2014 ; Nasir et al., 2022 ; Pashaei et al., 2023).

La réponse de MLP est exprimée dans l'équation 1 (Eq 1) :

$$\mathbf{g} = \int(\mathbf{w}\mathbf{x}_i^k + \theta) \quad (\text{Eq 1})$$

Où :

\mathbf{g} : Vecteur de sortie du réseau de neurones MLP,

r : Vecteur de référence,

w : Vecteur de coefficient de pondération,

θ : Limite du seuil.

L'équation 2 (Eq 2) présente la contribution du neurone j de la couche k et le poids de biais pour le neurone j dans la couche k est indiqué par γ_{jk} et β_{jk} .

$$\gamma_{jk} = F_k(\sum_{i=1}^{N_{k-1}} w_{ij}\gamma_{j(k-1)} + \beta_{jk}) \quad (\text{Eq 2})$$

Avec :

w_{ij} : Poids de connexion,

F_k : fonction de transfert d'activation non linéaire.

2.4. Processus de modélisation des réseaux de neurones artificiels

Selon Salas et Smith (1981), le processus de modélisation suit généralement plusieurs étapes principales, à savoir l'identification et la séparation des séries temporelles, l'identification des types de modèles, l'apprentissage ou l'estimation des paramètres du modèle et enfin la validation ou le test d'adéquation du modèle (Salas & Smith, 1981). Pour appliquer la modélisation à une série temporelle, la série doit être divisée en deux parties : la première consiste à apprendre le modèle choisi à partir d'observations connues, et la seconde consiste à tester le modèle lui-même en évaluant sa précision. Des études empiriques ont montré que des résultats optimaux sont obtenus avec 70 % des données utilisées pour l'apprentissage et les 30 % restants pour la validation, ce qui a également été prouvé statistiquement par (Gholamy et al., 2018).

Dans le domaine des réseaux de neurones artificiels, la "back-propagation" et le "nœud" sont des concepts cruciaux (Buscema, 1998). La "rétropropagation" fait référence au premier algorithme d'apprentissage utilisé pour mettre à jour les poids du réseau en minimisant la différence entre la sortie réelle et la sortie prédite. C'est une composante cruciale de l'apprentissage des réseaux de neurones, fondée sur le calcul du gradient de la fonction de perte par rapport aux poids, ce qui permet d'effectuer des ajustements qui réduisent l'erreur dans les itérations suivantes (Shukla et al., 2021).

Il est important de noter que même si les ANN peuvent fournir des renseignements et des recommandations utiles, ils devraient être utilisés conjointement avec l'expertise du domaine et d'autres méthodes d'analyse pour prendre des décisions éclairées (Soori et al., 2023).

3. Théorie de méthode de surface de réponse (RSM)

La méthode de surface de réponse (RSM) est une technique multivariée qui a attiré l'attention des chercheurs dans le domaine de l'ingénierie environnementale en raison de sa capacité à traiter plusieurs facteurs d'intérêt tout en révélant les effets spécifiques et interactifs de variables indépendantes avec un nombre limité de points de données (Bruns et al., 2006 ; Bypour et al., 2024). Il s'agit d'un outil approprié pour analyser, évaluer et modéliser le résultat de diverses variables interactives opérationnelles. Box et Behnken ont été les premiers à étendre la méthode, qui a été largement utilisée (Mu'azu & Olatunji, 2023). Pour appliquer la RSM, les chercheurs suivent généralement une procédure de conception en quatre étapes qui implique la conception d'un ensemble d'essais fiables d'une taille suffisante pour obtenir la réponse souhaitée, le développement d'un modèle mathématique avec un coefficient de corrélation élevé, l'identification des conditions expérimentales optimales qui aboutissent à une réponse minimale et maximale, et l'expression des effets directs et interactifs des variables du processus (Bahmanzadegan & Ghaemi, 2024) . Ces étapes sont essentielles pour utiliser la méthode RSM dans l'optimisation et la modélisation de processus complexes impliquant de multiples facteurs (Ghaemi et al., 2023 ; Gilmour, 2006).

La relation entre les facteurs d'entrée et la réponse est présentée dans l'équation 3 (Eq 3) (Mourabet et al., 2017).

$$Y = B_0 + \sum_1^k B_i X_i + \sum_1^k B_{ij} X_i X_j + \sum_1^k B_{ii} X_i^2 \quad (\text{Eq 3})$$

Les données fournies par cette équation sont utiles pour développer des processus plus efficaces. La variable de réponse qui dépend des facteurs d'entrée x_1, x_2, \dots, x_k est représentée par y , tandis que $\beta_0, \beta_i, \beta_{ii}$ et β_{ij} sont les coefficients de régression pour les termes fixe, linéaire, quadratique et interactif, respectivement.

4. Critères d'évaluation de la qualité de prévision des modèles ANN et RSM

Afin d'estimer les performances des modèles ANN développés, quatre indices statistiques largement utilisés ont été déterminés sur l'ensemble de données de l'apprentissage et la validation (Bardhan & Samui, 2022 ; Kotsiantis, 2007) :

Coefficient de détermination R^2 (coefficient of determination)

$$R^2 = \frac{\sum_{i=1}^N (d_i - d_{\text{mean}})^2 - \sum_{i=1}^N (d_i - y_i)^2}{\sum_{i=1}^N (d_i - d_{\text{mean}})^2} \quad -1 < R^2 < 1 \quad (\text{Eq 4})$$

MSE (Mean Squared Error : Erreur Quadratique Moyenne)

$$\mathbf{MSE} = \sum_1^N \sqrt{\frac{(y_i, p - y_i, a)^2}{N}} \quad (0 < \mathbf{MSE} < \infty) \quad (\text{Eq 5})$$

RMSE (Root Mean Squared Error : Racine Carrée de l'Erreur Quadratique Moyenne)

$$\mathbf{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\mathbf{d}_i - \mathbf{y}_i)^2} \quad (0 < \mathbf{RMSE} < \infty) \quad (\text{Eq 6})$$

MAE (Mean Absolute Error : Erreur absolue moyenne)

$$\mathbf{MAE} = \frac{1}{N} \sum_{i=1}^N (\mathbf{y}_i - \mathbf{d}_i) \quad (0 < \mathbf{MAE} < \infty) \quad (\text{Eq 7})$$

Où \mathbf{d}_i est la valeur observée, \mathbf{y}_i est la valeur prédite, \mathbf{d}_{mean} est la moyenne observée, N est la taille de l'échantillon.

Si ces résultats statistiques ne sont pas satisfaisants, l'architecture du réseau de neurones doit être mise à jour par un processus itératif afin de réduire l'écart entre les données simulées et observées. Ce processus inclut l'ajustement du nombre de couches cachées, du nombre de neurones dans chaque couche, des fonctions de transfert et des prédictions initiales de biais et de poids à un niveau acceptable (Fanoodi et al., 2019 ; Gomm, 1996 ; Heo & Lee, 2018; Shalaby et al., 2021; Sorsa & Koivo, 1993).

5. Indice de qualité de l'eau (Water quality index WQI)

5.1. Définition

WQI est une méthode mathématique couramment employée pour évaluer la qualité globale de l'eau à un endroit spécifique et à un moment précis (Soro et al., 2022). Cette grandeur sans dimension intègre des données de plusieurs paramètres de qualité de l'eau dans une équation mathématique dont chaque méthode comporte une échelle d'évaluation pour décrire l'état de la qualité de l'eau aux points de prélèvement choisis pour une enquête approfondie (Joshi et al., 2009 ; Rahgoshay et al., 2018 ; Tibebe et al., 2019 ; Uddin et al., 2021).

5.2. Historique

Les WQI ont été utilisés pour la classification de la qualité de l'eau au milieu des années 1800, bien que les modèles WQI n'aient été développés que depuis 50 ans (Abbasi & Abbasi, 2012). Dont le premier modèle de WQI a été créé par Horton dans les années 1960 en se basant sur dix paramètres de qualité de l'eau considérés comme importants dans la plupart des plans d'eau (Horton, 1965). Brown, a développé le modèle NSF-WQI, une version plus rigoureuse de WQI de Horton avec la sélection et de la pondération des paramètres (Abbasi & Abbasi, 2012). En 1973, le département Ecossais de développement de la recherche (SRDD) a créé son SRDD-WQI, inspiré du modèle NSF-WQI, pour évaluer la qualité de l'eau des rivières. Plusieurs modèles ultérieurs comme les indices de Dalmatien (Stambuk-Giljanović N, 2003), de House (1986) et de Bascaron (1979), sont tous basés sur le modèle SRDD-WQI.

Pra la suite, le modèle d'indice de la qualité de l'environnement a été créé par (Steinhart et al., 1981) pour évaluer la qualité de l'eau dans les écosystèmes. Au milieu des années 90, le modèle BCWQI a été créé par le ministère de l'environnement des terres et des parcs de la Colombie-Britannique, il a servi à évaluer l'état de la qualité de nombreux plans d'eau de la province de la Colombie Britannique au Canada (Saffran et al., 2001). En 2001, à la suite d'une révision du modèle BCWQI, le conseil Canadien du ministère de l'environnement a élaboré le modèle CCMEWQI (Lumb et al., 2011 ; Saffran et al., 2001 ; Uddin et al., 2022).

À ce jour, plus de 35 modèles WQI ont été introduits par divers pays et/ou organisations pour évaluer la qualité des eaux de surface dans le monde (Abbasi & Abbasi, 2012 ; Dadolahi-Sohrab et al., 2012; Kannel et al., 2007; Stoner et al., 1978).

5.3. Structure du modèle de WQI

La majorité des WQI se composent de quatre étapes principales (Abbasi & Abbasi, 2012 ; Abrahão et al., 2007 ; Lumb et al., 2011 ; Sutadian et al., 2018):

Etape 1 : Sélection des paramètres où il faut choisir un ou plusieurs paramètres de qualité de l'eau,

Etape 2 : Génération de nouveaux paramètres ou sous indices liés aux normes de qualité,

Etape 3 : Les valeurs de pondération des paramètres sont attribuées en fonction de leur importance pour l'évaluation,

Etape 4 : A l'aide d'une fonction mathématique, les sous-indices des paramètres individuels sont combinés avec les valeurs de pondérations pour donner un seul indice global appelé l'indice de qualité des eaux WQI. Ensuite, une échelle d'évaluation permettant de classer la qualité de l'eau à partir de cet indice global.

Dans le chapitre suivant, nous dévoilerons les principaux paramètres pris en compte et les formules spécifiques appliquées pour parvenir à nos résultats.

6. Utilisation des ANN et RSM dans la modélisation de l'indice de qualité de l'eau

Depuis quelques années, dans le cadre de développement durable et de la protection de l'environnement contre la pollution de l'eau, les recherches sur la prédiction de la qualité de l'eau à l'aide de techniques d'intelligence artificielle (IA) marquent un intérêt croissant pour la prédiction de WQI.

L'intelligence artificielle (IA) est une nouvelle technologie puissante capable de modéliser de nombreux problèmes complexes en temps réel. Les capacités de modélisation de la technologie de l'IA sont très utiles dans les processus de purification de l'eau et de traitement des eaux usées, car l'automatisation de ces installations rend les opérations simples et rentables et réduit considérablement les erreurs humaines. Les techniques d'IA impliquent des relations multilinéaires ou non linéaires qui ne peuvent souvent pas être modélisées à l'aide de méthodes conventionnelles (Safeer et al., 2022). La surveillance de la qualité de l'eau est essentielle pour protéger l'environnement et la santé humaine. La classification et la prévision de la qualité de l'eau peuvent être améliorées grâce à ces méthodes de IA (Nasir et al., 2022).

En tant qu'outil de gestion de problèmes complexes, la technologie de l'intelligence artificielle est de plus en plus explorée pour améliorer les performances des stations d'épuration (Kern et al., 2014 ; Mercier et al., 2019 ; Mokhtari et al., 2020; Nguyen et al., 2022; Nourani et al., 2018;

Radović et al., 2022.; Sundui et al., 2021; Xin et al., 2020; Yoo et al., 2008) et ces résultats d'analyse de données sont meilleurs que l'évaluation statistique traditionnelle (Ye et al., 2020). Dans le domaine des sciences de l'eau et de l'environnement, il a été prouvé que les réseaux neuronaux artificiels (ANN) fournissent de meilleurs résultats que d'autres méthodes statistiques pour modéliser l'indice de qualité de l'eau (WQI) en raison de leur structure adaptative et de leurs puissants algorithmes d'optimisation. Cette approche a été appliquée depuis le début des années 2000 pour prédire l'indice de qualité de l'eau (WQI) à travers les études suivantes (Abba et al., 2021 ; Barzegar et al., 2023; Charulatha et al., 2017; Chen et al., 2020; Gazzaz, 2012; Juahir et al., 2010; Krtolica et al., 2021; S. Li et al., 2019; Najafzadeh & Basirian, 2023; Setshedi et al., 2021; Trach et al., 2022; Xia et al., 2022 ; Mellal et al., 2024).

En ce qui concerne les investigations scientifiques relatives aux eaux de surface, plusieurs études se sont concentrées sur le Danube et le Bas-Danube, notamment celles menées par (Calmuc et al., 2020; Calmuc et al., 2021 ; Georgescu et al., 2023; Iticescu et al., 2016, 2019; Krtolica et al., 2021; Manoiu & Crăciun, 2021; Paun et al., 2017; Siriwardhana et al., 2023).

Par ailleurs, diverses investigations ont été entreprises en exploitant les avantages de l'intelligence artificielle pour utiliser l'indice de qualité de l'eau, dans le but d'évaluer la qualité des eaux souterraines (Bindu et al., 2023 ; Charulatha et al., 2017; Ismail et al., 2023; Kouadri et al., 2021; Kulisz et al., 2021; Kulisz & Kujawska, 2021; Ramakrishnaiah et al., 2009; Sravani et al., 2023; Sunayana et al., 2020; Udeshani et al., 2020) .

Une méthode alternative pour prédire l'indice de qualité de l'eau repose sur l'utilisation de réseaux de neurones artificiels (ANN) exploitant des données d'imagerie satellitaire (Li et al., 2022 ; Najafzadeh & Basirian, 2023 ; Zhang et al., 2021).

Pour prédire l'indice de qualité de l'eau (WQI), Hore et al., (2008) ont utilisé le perceptron multicouche (MLP) considérant les variabilités saisonnières et géographiques des paramètres des eaux usées dans des conditions naturelles comme des paramètres d'entrée. Salman Dawood et al., (2016) ont proposé un réseau neuronal feedforward multicouche avec un modèle de rétropropagation pour prédire les paramètres de qualité de l'eau tels que la turbidité, la dureté totale, les solides dissous totaux et la conductivité électrique de la rivière Shatt Al Arab. El Yousfi et al., (2023) ont utilisé le MLP pour prédire la qualité des eaux souterraines dans le Ghiss-Nekkor aquifer, au nord-est d'Al Hoceima, au Maroc et ce modèle a donné de bonnes performances prédictives pour le coefficient de corrélation R et RMSE.

Chen et al., (2020) ont déclarés que les modèles ANN présentent un fort potentiel pour résoudre les problèmes de prédiction de la qualité des eaux de surface et souterraines.

Hameed et al., (2017) ont appliqué un modèle combiné d'un réseau neuronal à fonction de base radiale (RBFNN) et un réseau de neurone à rétropropagation (BPNN) pour examiner et reproduire la relation entre WQI et les variables de la qualité de l'eau dans un environnement tropical (Malaisie). D'après cette étude, le RBFNN offre une grande précision pour la prédiction de WQI.

Une autre méthode qui a prospéré dans le même domaine de l'eau et l'environnement est la méthode de surface de réponse (RSM), un modèle mathématique empirique statistique design of experiments (DOE) utilisant la conception de Box-Behnken (BBD) pour créer des modèles de régression multiples où les variables de sortie peuvent être mesurées en fonction de l'effet des variables d'entrée (Kachroud et al., 2019 ; Rufina et al., 2023 ; Willmott, 1981). Iticescu et al., (2019) ont utilisé l'analyse en composantes principales (ACP) et la méthode de la surface de réponse (RSM) dans le but de prédire et corrélérer l'indice de qualité de l'eau en fonction des paramètres physico-chimiques dans lower Danube.

Roy et al., (2017) ont évalué la qualité de l'eau à Tripura, en Inde à l'aide de Analytic Network Process (ANP) et du modèle RSM, ce dernier a permis de déterminer l'importance des critères de qualité.

Mottahedin & Abdoos, (2021) ont évalué la qualité de l'eau de la rivière Hablehroud à l'aide de l'indice iranien de la qualité de l'eau pour les ressources en eau de surface-paramètres conventionnels (IRWQISC) et de la méthodologie de surface de réponse (RSM). Dans cette étude 11 paramètres physicochimiques ont été sélectionnés par la méthode Plackett-Burman, puis analysés par la méthode RSM-BBD, seulement cinq paramètres ont été retenus avec un coefficient de détermination (R^2) de 0,9982, indiquant la validité du modèle.

Gaya et al., (2020) présentent des techniques d'intelligence artificielle (IA) et la régression multilinéaire (MLR) comme le modèle linéaire classique pour estimer WQI de la station de Palla de la rivière Yamuna, en Inde. Jian et al (2020) étudient les modèles de WQI et des hydrocarbures aromatiques polycycliques (HAP) le long de la rivière Johan à Perak, en Malaisie, qui a reçu des lixiviats traités provenant d'une décharge voisine. L'objectif de (Kulisz & Kujawska, 2021) est de présenter le potentiel de l'utilisation de la modélisation par réseau neuronal pour prédire l'indice de qualité de l'eau de surface pour la rivière Warta, en Pologne.

7. Conclusion

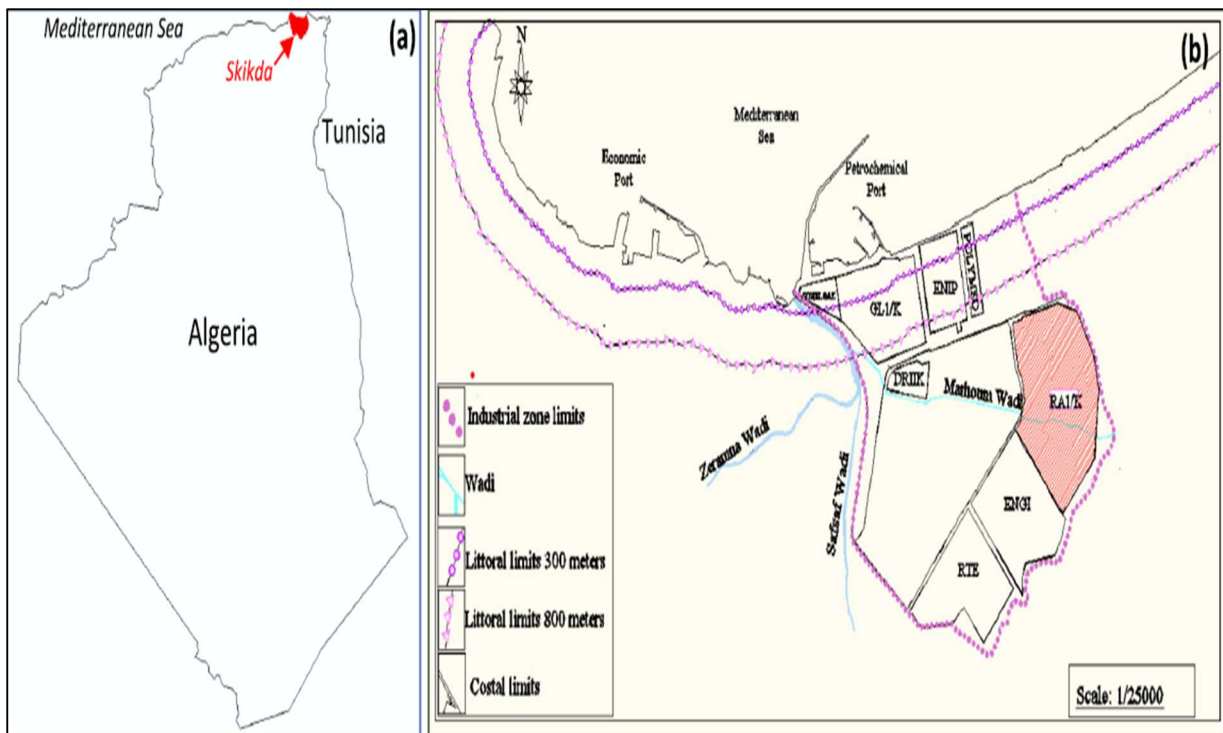
Au fil des dernières années, les recherches axées sur la gestion durable et la préservation de l'environnement face à la pollution de l'eau ont manifesté un intérêt croissant pour la prédiction de la qualité de l'eau au moyen de IA. L'IA, en tant que technologie novatrice, démontre une capacité puissante à modéliser divers problèmes complexes en temps réel. Ses capacités de modélisation s'avèrent particulièrement bénéfiques dans le traitement des eaux usées, où l'automatisation des installations simplifie les opérations, les rendant ainsi plus efficaces et économiques, tout en réduisant significativement les erreurs humaines.

Chapitre IV : Présentation de la zone d'étude

1. Contexte géographique de la zone d'étude

La Zone Industrielle de Skikda (ZI), située à l'est de la ville à une distance d'environ 4 km du chef-lieu de la wilaya, s'étend sur une superficie d'environ 1200 hectares. Elle est bordée au nord par les eaux de la mer Méditerranée, à l'est par la commune de Ben Mhidi, et au sud par la vallée de l'Oued Safsaf ainsi que la commune de Hamrouche Hamoudi. Gérée par la direction de la région industrielle de Skikda (DRIK), cette zone est caractérisée par une prédominance pétrochimique, regroupant plusieurs complexes spécialisés dans le raffinage, transport et traitement des hydrocarbures. Ces activités engendrent d'importantes quantités d'eaux usées, qui sont déversées soit directement dans la mer, soit par le biais de l'Oued Safsaf.

Le complexe de raffinage de pétrole de Skikda (RA1/K) se distingue comme l'une des installations pétrolières majeures du pays. Cependant, la production de ce complexe génère des eaux usées contenant divers polluants et substances indésirables. Pour traiter ces eaux usées et prévenir toute contamination environnementale, une station d'épuration (STEP) spécifiquement conçue est installée dans la Zone Industrielle (ZI). Cette station se trouve à proximité immédiate de la raffinerie, à seulement 500 mètres, et à environ 7 km du chef-lieu de la wilaya de Skikda (**Figure IV. 1**).



2. Contexte réglementaire des eaux usées industrielles en Algérie

En Algérie, le suivi des principaux rejets industriels est réglementé par l'annexe 1 du Journal Officiel de la République Algérienne du 23 avril 2006 (JORA, 2006), qui établit les valeurs limites des paramètres des effluents liquides industriels. Conformément à cette réglementation, les entreprises sont tenues de surveiller régulièrement la qualité de leurs rejets dans l'environnement (Morin-Crini, Crini, and Roy 2017) . Cette surveillance implique une autoévaluation de la nature et de la fréquence des mesures, allant de quotidiennes à hebdomadaires, etc., avec une obligation de transmettre périodiquement les données à la Direction de la Région Industrielle de Skikda (DRIK). De plus, le gouvernement peut effectuer des inspections inopinées des rejets par le biais d'organismes externes tels que l'Observatoire National de l'Environnement et du Développement Durable (ONEDD), qui valide les résultats de l'autosurveillance. Cette dernière vise à évaluer l'efficacité des processus de traitement des eaux usées et à intervenir rapidement en cas de dysfonctionnement (Djelal, Rigail, and Boyer 2008).

3. Contexte climatique de la zone d'étude

Pour obtenir une caractérisation plus approfondie du climat dans la région de Skikda, nous avons analysé les données recueillies au port, situé à proximité de la zone industrielle, sur une période de vingt ans, allant de 2002 à 2022.

La région de Skikda se trouve dans l'étage bioclimatique subhumide, se distinguant par une pluviométrie moyenne annuelle de 702 mm. Les précipitations les plus importantes sont enregistrées principalement durant les mois de décembre (120 mm), janvier et novembre (100 mm), février (85 mm) et octobre (70 mm). En revanche, le mois le plus sec est août, avec seulement 2 mm de précipitations (**voir Figure IV.2**).

Le climat de la wilaya de Skikda est généralement tempéré, avec une température moyenne mensuelle la plus basse de 12,9 °C enregistrée pendant les mois de janvier et février. La température moyenne la plus élevée, quant à elle, est de 26,3 °C en août, et la température moyenne annuelle s'établit à 18,87 °C (**voir Figure IV.3**).

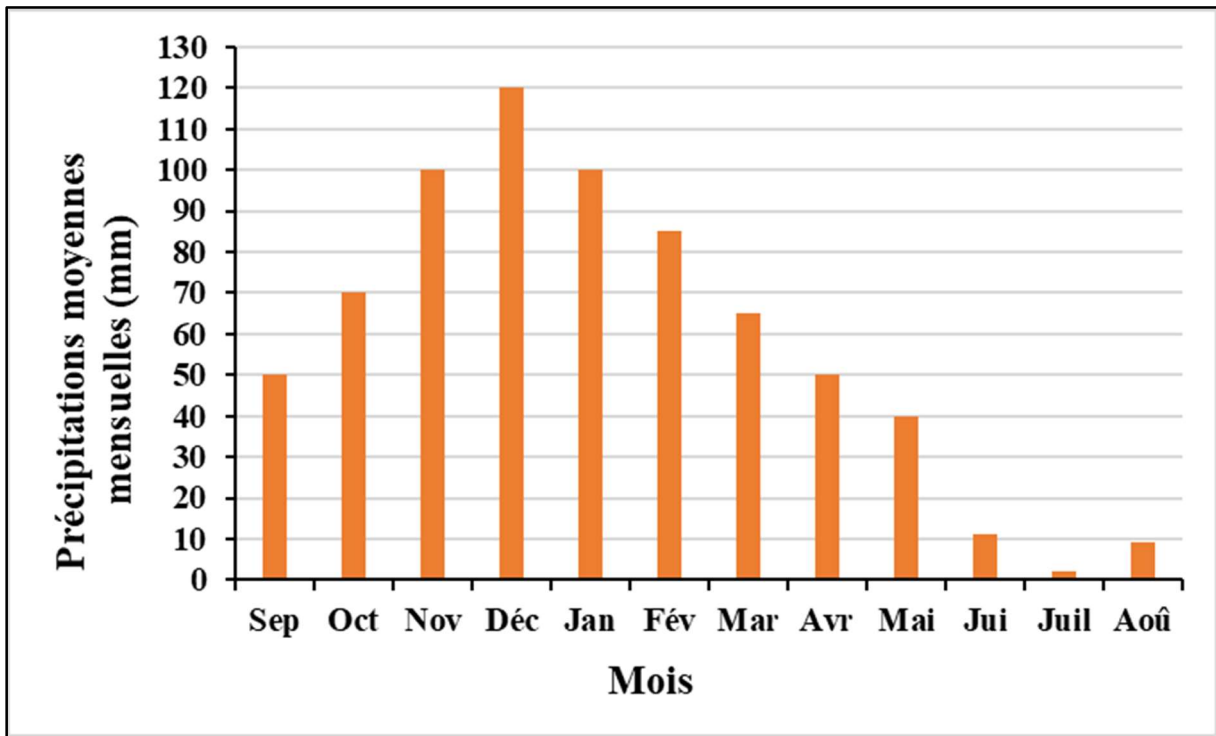


Figure IV.2. Précipitations moyennes mensuelles de Skikda (ONM, 2022).




Figure IV.3. Températures moyennes mensuelles de Skikda (ONM, 2022).

En outre, le diagramme ombrothermique de Gaussen, construit à partir des données de température et de précipitations, présente deux périodes distinctes pour la région de Skikda (2002-2022) (voir **Figure IV.4**). Une période sèche s'étend sur cinq mois de l'année, de mai au début de septembre, tandis qu'une période humide couvre les autres mois, de mi-septembre à avril. Cette représentation souligne les variations saisonnières significatives du climat dans la région, avec des périodes de sécheresse suivies de saisons de précipitations plus abondantes.




Figure IV.4. Diagramme ombrothermique de Gaussen de Skikda (ONM, 2022).

4. Description de la STEP de la raffinerie de Skikda (RA1/K)

L'installation est spécifiquement dimensionnée pour traiter un débit moyen quotidien de 10 800 m³ par jour par temps sec, avec une capacité de 330 000 équivalents-habitants et un débit horaire maximum de 4 400 m³/h. Lors de sa conception, les paramètres de qualité de l'eau brute étaient estimés à 320 mg/l pour la DBO₅, 570 mg/l pour la DCO, 60 mg/l pour les MES, 79 mg/l pour les hydrocarbures totaux (CxHy), 13 mg/l pour l'indice de phénol et 7 mg/l pour l'azote total Kjeldahl (TNK). La qualité des rejets doit être conforme aux limites fixées par JORA, 2006 et être inférieure à 35 mg/l de DBO₅, 120 mg/l de DCO et 35 mg/l de MES, 10 mg/l de CxHy, 0,3 mg/l d'indice phénolique et 30 mg/l d'azote total Kjeldahl. Dans cette étude, nous nous intéressons particulièrement à la qualité de l'eau à la fin du traitement de polissage, mais la ligne de boues n'est pas incluse.

Cette unité de traitement assure un processus efficace et respectueux de l'environnement pour les eaux usées issues des activités industrielles. Ce processus d'épuration est hautement sophistiqué, comprenant plusieurs étapes clés (voir Figure IV.5) :

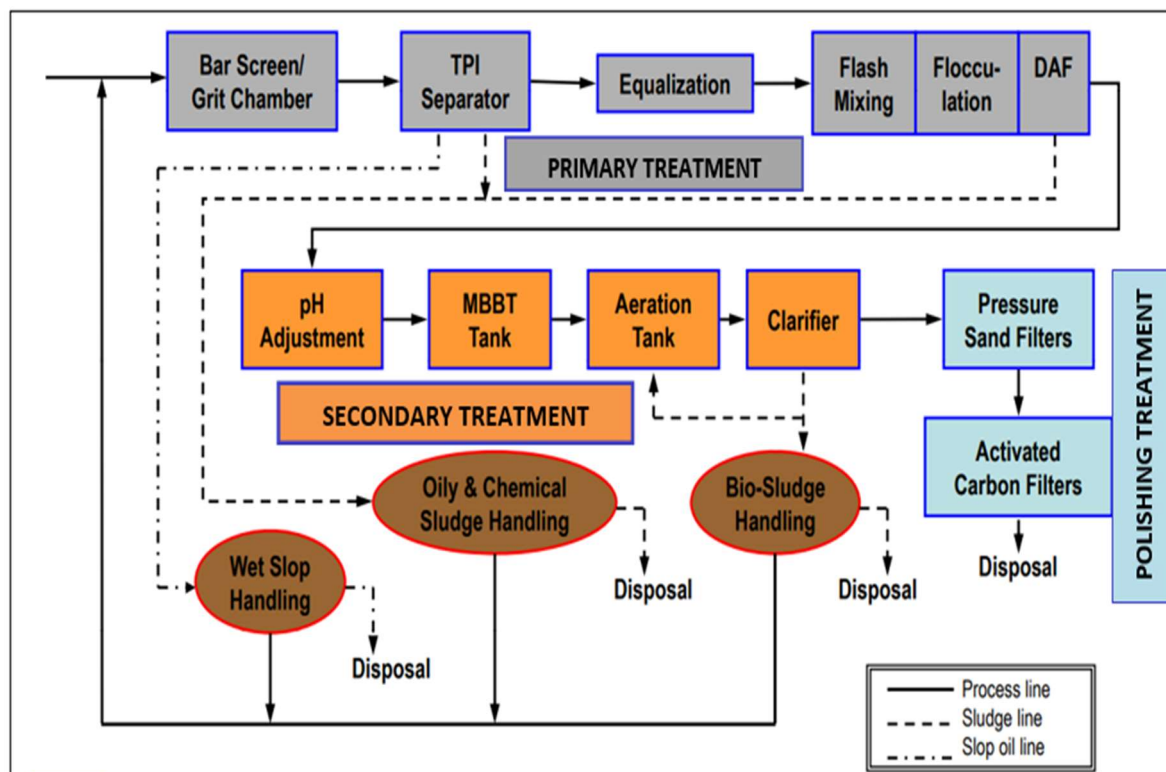


Figure IV.5. Station d'épuration des eaux usées de la RA1/K de Skikda.

4.1. Prétraitement

Les eaux usées générées par les diverses unités opérationnelles de la raffinerie sont centralisées et acheminées vers la phase initiale de prétraitement. Cette étape préliminaire revêt une importance capitale car elle vise à éliminer les matières grossières. Les débris solides, les matières grasses et d'autres substances facilement séparables sont ainsi éliminés avant que les eaux usées n'entrent dans le système de traitement primaire (Von Sperling 2007). Cette première étape de prétraitement est cruciale pour garantir l'efficacité globale du processus d'épuration, on réduit le risque de colmatage des équipements ultérieurs et on améliore la performance globale du système de traitement. De plus, l'élimination préliminaire des matières grasses et d'autres substances séparables contribue à réduire la charge organique entrant dans les unités de traitement primaires, ce qui favorise une efficacité accrue du traitement global.

4.2. Traitement primaire

Le traitement primaire constitue la deuxième phase essentielle du processus de purification des eaux usées au sein de cette STEP. Cette étape est conçue pour éliminer les contaminants solides et dissous présents dans les eaux usées, il comprend les étapes suivantes (**Figure IV.6**):

4.2.1. Grille et chambre à sable (Bar screen and greet chamber)

Dans cette étape, les effluents sont dirigés vers une grille et une chambre à sable spécialement conçues pour éliminer les déchets grossiers présents dans les eaux usées. Ces déchets comprennent généralement des matériaux tels que le bois, gravier, le sable et d'autres débris de taille similaire. Le rôle principal de cette étape est de réaliser une élimination physique efficace de ces contaminants grossiers, ce qui permet non seulement de faciliter les étapes ultérieures du traitement, mais aussi de protéger les équipements sensibles de la station d'épuration, tels que les pompes et les tuyauteries, contre tout endommagement potentiel.

La grille et la chambre à sable sont des éléments clés de ce processus, conçus pour capturer et retenir les déchets grossiers tout en permettant aux effluents liquides de passer à travers. La grille est composée de barreaux disposés de manière à former une structure à mailles serrées, avec un espacement net entre les barreaux de moins de 25 mm, afin de capturer efficacement les débris de taille supérieures. Ces barreaux sont régulièrement inspectés et nettoyés manuellement pour garantir un fonctionnement optimal du système.

4.2.2. Séparateur TPI (TPI separator: Intercepteur à plaques inclinées)

Les effluents provenant de l'étape précédente sont dirigés vers une unité de séparation huile-eau équipée de packages d'intercepteur à plaques inclinées (TPI). L'objectif principal de cette unité est d'éliminer les solides en suspension ainsi que l'huile libre présente dans les eaux usées, en exploitant la différence de densité entre ces différentes phases et l'eau.

Les intercepteurs à plaques inclinées sont conçus avec un angle d'inclinaison typique de 40° à 50°, ce qui permet une séparation efficace des différentes phases. L'espacement entre les plaques est minutieusement réglé, généralement entre 16 et 22 mm, afin de permettre une élimination optimale de l'huile libre et des solides en suspension. Cette configuration assure que les phases plus légères, telles que l'huile, remontent à la surface tandis que les solides en suspension plus lourds sont piégés entre les plaques inclinées.

En outre, ces unités sont équipées d'installations de réchauffage de serpentin à vapeur, qui jouent un rôle crucial pendant les périodes froides. Ce système de réchauffage permet de maintenir une température adéquate dans l'intercepteur, favorisant ainsi une meilleure séparation de l'huile libre des eaux usées même en temps froid, où la viscosité de l'huile peut augmenter et rendre la séparation plus difficile.

4.2.3. Réservoir d'égalisation (Equalization: OWS)

Cet ouvrage est spécifiquement conçu pour jouer un rôle crucial dans le maintien des charges de pointe et la stabilisation des fluctuations de débit dans le processus de traitement des eaux usées. Son objectif principal est d'éliminer les couches d'huile flottante et la boue de fond, préparant ainsi les eaux usées aux étapes ultérieures. Il convient de noter que bien que ce réservoir aide à stabiliser le flux des eaux usées, il n'entraîne pas de changement significatif dans la qualité de l'eau. Ce système comprend également :

- Les réservoirs de mélange rapide (Flash mixing)

Ils sont conçus avec des agitateurs à turbine de 0,5 à 2 minutes pour fournir un mélange rapide avec du sulfate d'aluminium, un flocculant qui s'injecte au point de turbulence maximale et minimise les courts-circuits.

- Les réservoirs de floculation (Flocculation)

Dans ces réservoirs, les eaux usées sont soumises à un processus de floculation qui dure généralement entre 15 et 20 minutes. Pendant cette phase, les ions aluminium et les molécules d'eau réagissent pour former des précipités d'hydroxyde, ce qui contribue à neutraliser la charge électrique des particules en suspension dans l'eau. Cette neutralisation facilite le

processus de floculation, où les solides en suspension s'agrègent pour former des flocons qui sont plus faciles à éliminer par décantation. De plus, des ajustements de pH sont effectués en injectant de l'acide sulfurique ou de la soude caustique au besoin, tandis qu'un polyélectrolyte de déshuilage (DOPE) est ajouté pour favoriser la formation de floes plus gros et améliorer leur décantation.

4.2.4. Flottation à air dissous (Dissolved Air Flotation : DAF)

Après élimination d'huile libre et égalisation des flux, cette étape, constitue un processus essentiel pour l'élimination de l'huile émulsionnée dans les eaux usées. Ce système repose sur un principe simple mais efficace, qui consiste à utiliser un agitateur à palette pour injecter un désémulsifiant dans le flux pendant une durée de 20 à 30 minutes. Cette injection de désémulsifiant vise à rompre l'émulsion d'huile dans l'eau, sans générer de quantités significatives de boues excédentaires dans les réservoirs désémulsifiants.

Une fois que l'émulsion d'huile a été brisée, le processus de flottation à air dissous peut commencer. Dans cette étape, de l'air comprimé est introduit dans le flux pour saturer l'eau en fines bulles d'air. Ensuite, l'eau est ramenée à la pression atmosphérique, ce qui libère les bulles d'air attachées aux particules présentes dans le flux. Ces bulles d'air agissent pour augmenter la flottation des particules d'huile émulsionnée, les faisant remonter à la surface du réservoir où elles peuvent être facilement collectées et éliminées.

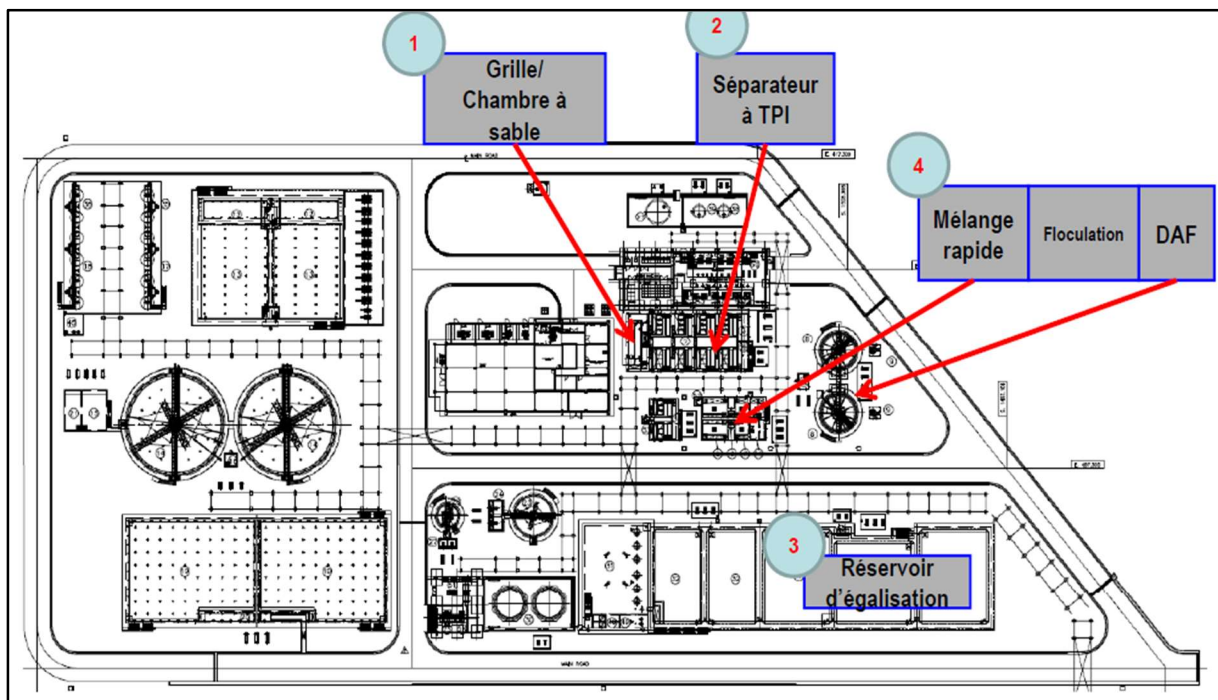


Figure IV.6. Traitement primaire

4.3. Traitement secondaire (traitement biologique)

Le traitement secondaire, également connu sous le nom de traitement biologique, constitue une étape essentielle dans le processus d'épuration des eaux usées. Cette phase vise à éliminer davantage de polluants organiques et autres contaminants présents dans les flux traités précédemment, en utilisant des processus biologiques et physico-chimiques spécifiques (**figure IV.7**) :

4.3.1. Ajustement de pH (pH ajustement)

Les eaux usées huileuses prétraitées sont dirigées vers le réservoir d'ajustement du pH, où un processus d'ajustement est effectué pour garantir des conditions optimales pour l'activité microbienne. Ce réservoir est équipé d'un agitateur pour assurer une distribution homogène des réactifs, ainsi que des réservoirs de dosage de caustique et de solution acide pour ajuster le pH dans une plage de 6,5 à 7,5. Maintenir le pH dans cette plage spécifique est crucial pour assurer une efficacité maximale de la masse microbienne dans l'élimination des polluants organiques.

4.3.2. Réservoir à filtrant sur lit mobile (MMBT Tank: Moving Bed Biofilm Reactor)

Après l'élimination des huiles libre et émulsionnée et l'ajustement du pH, les effluents huileux sont introduits dans le réservoir à filtrant sur lit mobile (MMBT) pour le traitement biologique. Cette étape est considérée comme la première phase du biotraitement pour éliminer partiellement la DBO₅. La technologie MBBT utilise des milliers de conteneurs de biofilm en polyéthylène disposés dans un bassin aéré. Chaque bio-conteneur fournit une surface protégée pour favoriser la croissance bactérienne responsable de la biodégradation des polluants organiques. Cette approche améliore la fiabilité et simplifie le fonctionnement du traitement biologique tout en nécessitant moins d'espace que les systèmes traditionnels de traitement des eaux usées.

4.3.3. Réservoir d'aération et clarificateur (Aeration tank and clarifier)

Le réservoir d'aération et le clarificateur représentent la deuxième phase du traitement biologique. Dans le réservoir d'aération, les boues activées sont recirculées, tandis que la diffusion d'oxygène est assurée pour maintenir des conditions aérobies favorables à l'activité microbienne. Les clarificateurs, quant à eux, sont conçus pour séparer autant de biomasse que possible des eaux traitées, fournissant ainsi de l'eau clarifiée pour un traitement ultérieur.

Ces deux composantes travaillent ensemble pour assurer une élimination maximale des polluants organiques et une qualité d'eau adéquate avant le rejet dans l'environnement.

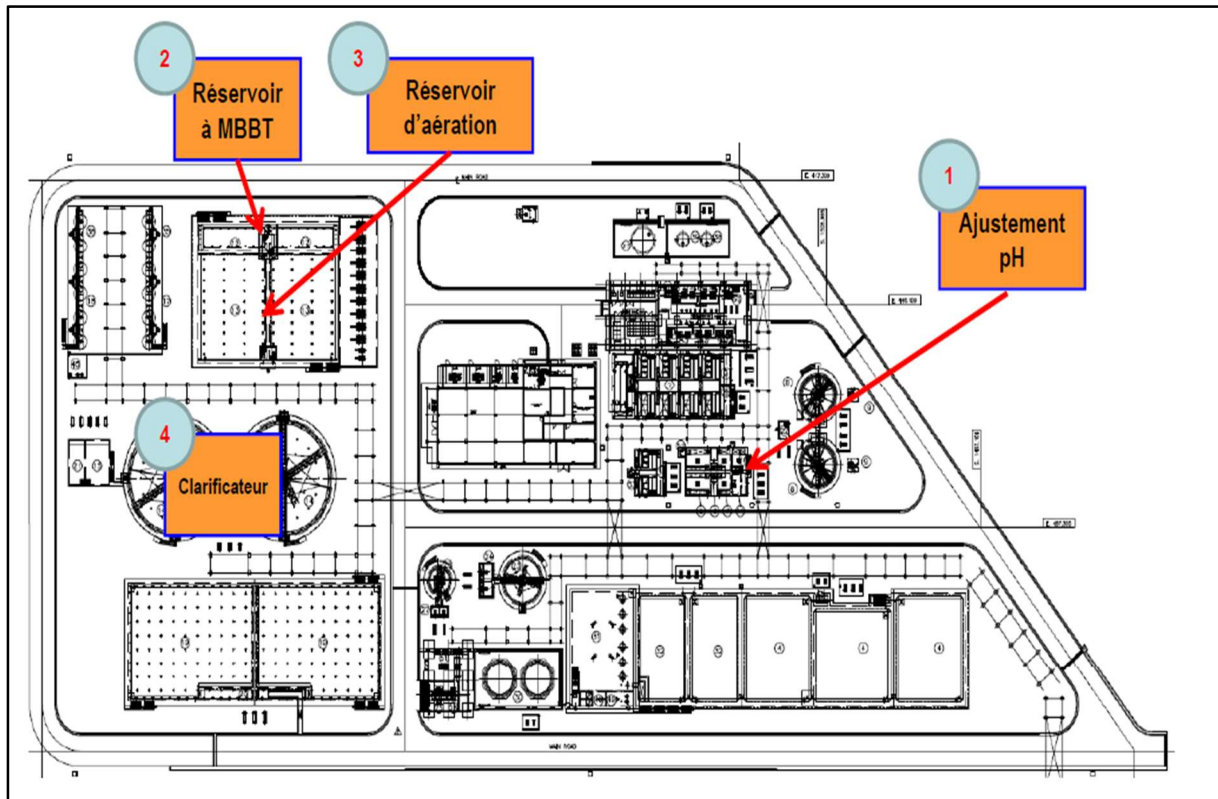


Figure IV.7. Traitement secondaire

4.4. Traitement de polissage (Polishing treatment)

Le traitement de polissage, la phase finale du processus de traitement des eaux usées, vise à améliorer la qualité globale de l'eau traitée avant son rejet dans l'environnement tout en éliminant encore davantage les contaminants résiduels tels que les MES, la DBO₅ et réduire la DCO à travers les étapes suivantes (**Figure IV.8**) :

4.4.1. Filtre à sable de pression (Pressure sand filters: PSF)

Cette étape implique l'utilisation de filtres à sable sous pression pour éliminer les résidus solides en suspension restants dans les eaux traitées. Les filtres à sable agissent en piégeant les particules solides alors que l'eau passe à travers le lit de sable, assurant ainsi une filtration efficace des matières en suspension.

4.4.2. Filtre à charbon activé (Activated carbon filters : ACF)

Cette étape consiste à faire passer les eaux traitées à travers des filtres à charbon activé pour éliminer la matière organique résiduelle, y compris la DBO₅ et la DCO, ainsi que d'autres hydrocarbures. Le charbon activé est connu pour son fort pouvoir d'adsorption, ce qui lui permet de piéger efficacement les composés organiques présents dans l'eau, améliorant ainsi significativement sa qualité.

4.4.3. Bassin de protection

Enfin, les effluents traités passent par un bassin de protection, où leur qualité est vérifiée et homogénéisée avant le rejet final dans l'environnement. Ce bassin joue un rôle crucial dans la surveillance finale de la qualité de l'eau traitée et garantit que les effluents répondent aux normes environnementales. À la fin de cette phase de traitement de polissage, la qualité de l'eau traitée rejetée dans l'oued Marhom a été estimée à 35 mg/l de DBO₅, 120 mg/l de DCO, 30 mg/l de MES, 6 mg/l d'huile émulsionnée et 2 mg/l d'huile libre. Ces niveaux sont conformes aux normes réglementaires et représentent une qualité d'eau adéquate et peut être rejetée en toute sécurité dans l'environnement.

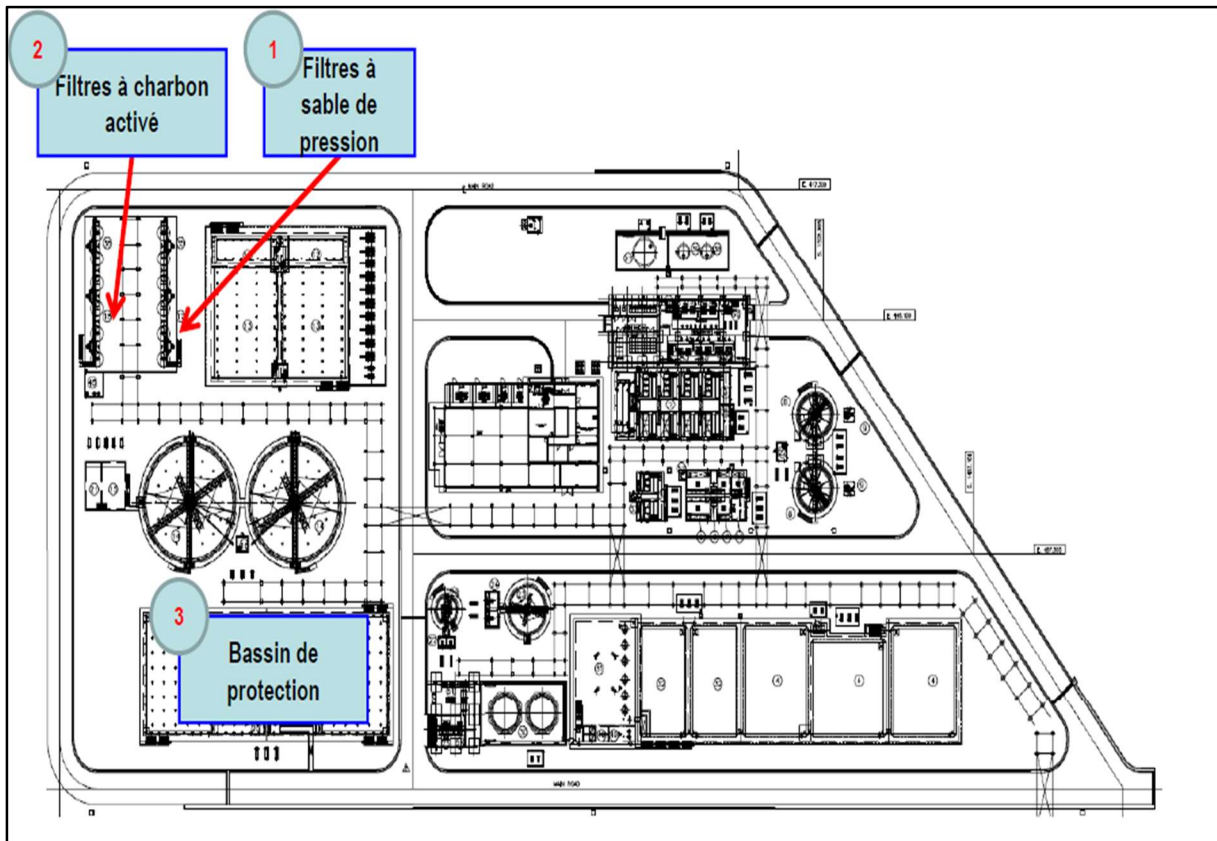


Figure IV.8. Traitement de polissage

5. Echantillonnage et méthodes d'analyses des eaux usées

L'échantillonnage est effectué, en se référant à (Rodier et al, 2009), sur une période allant d'octobre 2020 au mars 2023. Les prélèvements d'eau ont été réalisés dans des flacons en verre de 1 litre préalablement lavés, rincés et séchés à l'étuve à 100°C puis fermés hermétiquement pour éviter toute contamination probable. Ensuite, les échantillons sont acheminés directement au laboratoire de la raffinerie pour les analyser. En effet, les mesures de température (T), de pH, et de conductivité électrique (CE), ont été réalisées in situ à l'aide d'un analyseur multi-paramètres type HORIBA, modèle U22. Tandis que le reste des paramètres ont été analysés au laboratoire tels que la Demande Chimique en Oxygène (DCO), le phosphate total (PO_4^{3-}) et les hydrocarbures totaux (CxHy). Toutes les analyses et les mesures nécessaires pour quantifier la pollution sont normalisées suivant les normes Algériennes, similaires aux normes françaises AFNOR selon les techniques préconisées par (Rodier et al. 2009).

5.1. Mesure de la demande chimique en oxygène (DCO)

La demande chimique en oxygène (DCO) est un outil d'analyse et de planification du procédé de dépollution. Elle compte parmi les paramètres globaux de pollution et représente la quantité d'oxygène nécessaire pour épurer une eau. Souvent utilisée pour le suivi des performances des installation de dépollution offrant ainsi une idée sur la qualité du traitement. En effet, c'est un indice de référence pour autoriser une telle station à déverser ses eaux dans le milieu naturel.

La détermination de la DCO a été effectuée conformément à la méthode NF T90-101, qui implique une oxydation en milieu acide avec un excès de dichromate de potassium, de sulfate d'argent et de sulfate de mercure (II), selon le protocole expérimental suivant :

Un volume de 10 ml d'échantillon a été versé dans un Erlenmeyer de 300 ml. Ensuite, 1g de sulfates d'argent a été ajouté, suivi de l'addition de 5 ml d'acide sulfurique et de 10 ml de permanganate de potassium (N/40). Le contenu a été soigneusement mélangé pour assurer une réaction homogène.

Essai à blanc

Les mêmes réactifs utilisés dans l'étape précédente ont été employés, mais avec l'addition de 5 ml d'eau distillée.

Les échantillons ont été chauffés sur un bain-marie pendant une période de 30 minutes, maintenus à une température située entre 60°C et 80°C. Par la suite, 10 ml d'oxalates de

sodium ($\text{Na}_2\text{C}_2\text{O}_4$) ont été ajoutés. Le titrage a été réalisé avec une solution de KMnO_4 (N/40).

5.2. Dosage du phosphore total (PO_4^{3-})

Le phosphore, un élément essentiel de la matière organique et vital pour la nutrition des organismes vivants, présente des émissions dans les milieux aquatiques qui posent de sérieux problèmes environnementaux, en accélérant notamment l'eutrophisation, selon Banas & Lata. (2006). Lorsque sa concentration dépasse 0,5 mg/l, il devient un indicateur de pollution et contribue à la dystrophisation de l'environnement récepteur, comme l'indique (Rodier et al. 2009). La concentration maximale admissible de phosphore dans les rejets d'effluents liquides industriels ne doit pas dépasser 10 mg/l, selon les réglementations algériennes (JORA, 2006). Il se trouve dans les eaux usées sous forme de composés organiques et de sels minéraux, notamment les orthophosphates et les polyphosphates. Sawadogo (2018) mentionnait que le traitement primaire et secondaire des eaux usées élimine environ 10 à 30 % du phosphore, tandis que le traitement biologique, par l'absorption cellulaire de luxe, améliore cette élimination grâce à l'action de microorganismes spécialisés appelés organismes accumulateurs de phosphore (OAP), qui peuvent absorber de 7 à 8 % du phosphore, comme l'ont souligné (Templeton and Butler 2011).

Le phosphore total est dosé selon la méthode NF EN ISO 6878 (avril 2005) par spectrophotométrie au molybdate d'ammonium (indice de classement T90-023).

Cette technique peut être utilisée pour tout type d'eau, y compris les eaux industrielles, qui peuvent être analysées sans dilution, dans un intervalle de 0.005 à 0.8 mg/l.

Avec une limite de détection d'environ 0,000 5 mg/l, un mode d'extraction au solvant permet de mesurer des concentrations en phosphore plus faibles.

Mode opératoire

Mettre 20 ml d'eau dans une fiole de 25 ml pour l'analyse. Ajouter un millilitre de solution d'acide sulfurique et agiter. Ensuite, ajouter 4 ml de solution d'ammonium de molybdate, mélanger et attendre 30 minutes. La présence de PO_4 est indiquée par la stabilisation de la coloration bleue.

Expression des résultats

Les concentrations en (mg/l) sont lues par spectrophotomètre à 880 nm et obtenues par l'équation suivante :

$$[PO_4] = \frac{(A - A_0) * f * V_{max}}{V_s}$$

Où :

A : L'absorbance de la prise d'essai ;

A₀ : L'absorbance de l'essai à blanc ;

f : L'inverse de la courbe d'étalonnage ;

V_{max} : Volume maximale de la prise d'essai (40 ml) ;

V_s : Volume de la prise d'essai en ml.

5.3. Dosage des hydrocarbures totaux

Les hydrocarbures représentent une part importante des pétroles bruts, constituant généralement entre 65% et 95% de leur composition totale. Ces hydrocarbures se divisent en quatre grands groupes, comprenant les hydrocarbures saturés (30% à 70%), les composés aromatiques et polyaromatiques (20% à 40%), les composés extrêmement lourds (5% à 25%) et le bitume (0% à 10%) (Soltani, 2005).

Malgré la nécessité de maintenir une teneur en hydrocarbures dans les rejets d'eaux usées industrielles inférieure ou égale à 10 mg/l, conformément aux normes réglementaires (JORA, 2006), leur détection et quantification restent des procédures critiques. Les hydrocarbures sont généralement dosés selon la méthode AFNOR NF EN ISO 9377-2 :2000, qui implique l'utilisation de la chromatographie gazeuse avec un détecteur à ionisation de flamme et l'extraction par l'hexane, contenant deux étalons internes (C10 et C40).

Le processus de prélèvement des échantillons implique l'acidification de l'échantillon avec de l'acide phosphorique ou chlorhydrique après son remplissage dans un flacon de 250 ml à plusieurs litres, selon la concentration en hydrocarbures. Le flacon est ensuite hermétiquement fermé et conservé à une température de 4°C pour garantir la stabilité de l'échantillon.

Le processus de dosage des hydrocarbures s'articule autour de trois étapes distinctes, assurant une mesure précise et fiable de leur concentration dans les échantillons d'eaux usées industrielles.

A. Extraction

L'échantillon aqueux, préalablement refroidi à une température de 10 °C ou moins, est acidifié à un pH de 2 à l'aide d'un acide minéral tel que l'acide chlorhydrique ou phosphorique. Ensuite, 80 à 100 grammes de sulfate de magnésium par litre d'échantillon sont ajoutés pour prévenir la formation d'émulsions. Au moins 50 ml de solvant d'extraction, contenant des étalons internes, sont utilisés par litre d'échantillon pour extraire les hydrocarbures, suivis de la séparation des deux phases.

b. Purification et concentration de l'extrait

L'extrait obtenu est asséché à l'aide de sulfate de sodium anhydre, puis filtré dans une mini-colonne contenant environ 2 g de "Florisil". Un volume de 10 ml de solvant d'extraction est versé dans la colonne, et si nécessaire, cette opération peut être réalisée en plusieurs étapes, la dernière sous courant d'azote ou d'hélium, jusqu'à obtenir un volume final de 1 ml.

c. Chromatographie

La chromatographie est effectuée sur une colonne capillaire apolaire (par exemple, un copolymère de diphényle diméthylpolysiloxane comme DB-1, OV-1, SE-30...) ou faiblement polaire (par exemple, un copolymère de cyanopropylphényle diméthylpolysiloxane comme DB-5...), avec un gradient de température. La détection et la quantification des hydrocarbures sont généralement réalisées par ionisation de flamme, bien que la spectrométrie de masse puisse également être utilisée.

Il est recommandé, lors de l'injection en chromatographie, d'utiliser une solution de n-décane dans l'hexane correspondant à la concentration prévue dans le concentrat final de 1 mL pour contrôler les pertes éventuelles dues à l'évaporation. Ce processus garantit une analyse précise et exhaustive des hydrocarbures présents dans les échantillons d'eaux usées industrielles.

Expression des résultats

L'indice hydrocarbure, exprimé en milligramme par litre est donné par la formule suivante :

$$r = \frac{(Am - b) * f * v * w}{a * (m_1 - m_2)}$$

Avec :

r : Indice hydrocarbure (mg/l) ;

a : la pente de la fonction d'échange en l/mg ;

Am : l'aire de pic intégré de l'extrait d'échantillon ;

f : facteur de dilution de l'extraction d'échantillon ;

m_1 : masse de flacon d'échantillon rempli (g) ;

m_2 : masse de flacon d'échantillon vide (g) ;

w : masse volumique en mg/l d'échantillon utilisé ;

v : volume de l'extraction finale (ml) ;

b : ordonnée à l'origine en unité correspondant à l'instrument.

6. Calcul de l'indice de qualité de l'eau (WQI)

Afin d'évaluer l'impact écologique de la qualité de l'eau rejetée par la STEP de la raffinerie sur la période d'observation, la méthode de l'indice de qualité de l'eau (WQI) pour décrire la qualité de l'eau. Cet indice a été calculé sur la base de la législation nationale Algérienne, à savoir le Journal Officiel de la République Algérienne n°26 du 23 avril 2006 – **Annex1** : Valeurs limites des paramètres de rejets d'effluents liquides industriels (JORA, 2006) ainsi que les normes relatives à la classification de la qualité des eaux de surface établies par l'Agence des Bassins Hydrographiques (ABH, 2009).

Dans la présente recherche, la méthode de l'indice arithmétique pondéré de la qualité de l'eau a été adoptée par plusieurs chercheurs (Abba et al., 2021 ; Tiyasha et al., 2020 ; Zhang et al., 2020) et calculée à l'aide de l'équation suivante :

$$WQI = \frac{\sum W_i * q_i}{\sum W_i}$$

Avec :

W_i : Le poids relatif et le facteur qui détermine l'importance d'un paramètre donné, il est calculé comme suit :

$$W_i = \frac{K}{S_i}$$

Avec:

K : Valeur constante, calculée comme suit :

$$K = \frac{1}{\sum \left(\frac{1}{S_i}\right)}$$

S_i : La valeur standard légalement acceptée par JORA (N°26/2006 – Valeurs limites des paramètres de rejets d'effluents liquides industriels) et les normes de classification de la qualité de l'eau de surface ABH (2009).

q_i : La valeur relative de la qualité de l'eau pour chaque paramètre, calculée comme suit :

$$q_i = 100 \frac{V_i - V_0}{S_i - V_0}$$

V_i : La valeur mesurée du $i^{\text{ème}}$ paramètre ;

V_0 : La valeur idéale du paramètre V_i , V_0 est 0 pour tous les paramètres, sauf pour le pH où on a pris $pH = 7$.

Selon les travaux de recherche récents (Georgescu et al., 2023 ; Iticescu et al., 2019), les eaux de surface sont généralement classées en cinq groupes en fonction de leur qualité :

G1 : de 0 à 25, correspondant à une eau de très bonne qualité ;

G2 : de 26 à 50, indiquant une eau de bonne qualité ;

G3 : de 51 à 75, caractérisant une eau de mauvaise qualité ;

G4 : de 76 à 100, signalant une eau de très mauvaise qualité ;

G5 : supérieure à 100, dénotant une eau extrêmement polluée.

En appliquant cette classification aux résultats de notre étude, il apparaît que le rejet de la raffinerie est globalement de bonne à très bonne qualité. En effet, les valeurs de l'indice de qualité de l'eau (WQI) varient de 0,66 à 49,20, avec une moyenne à 25,18. Ces résultats témoignent d'un niveau de pollution relativement faible, principalement dû à l'efficacité du procédé d'épuration mis en place au sein de la station d'épuration (STEP) de la raffinerie.

7. Conclusion

Au cours de notre étude, nous avons utilisé l'indice de qualité de l'eau (WQI) comme outil puissant pour synthétiser la complexité des données sur la pollution de l'eau. Cette approche nous a permis d'obtenir une évaluation quantitative de la qualité de l'eau en tenant compte des multiples paramètres mesurés. En utilisant l'indice WQI, nous avons pu obtenir une vision globale et cohérente de l'état de la qualité de l'eau dans la région étudiée.

Cette étape constitue une base solide pour le prochain chapitre de notre analyse, qui portera sur l'identification des variables d'entrée à travers l'utilisation de méthodes statistiques multivariées. En combinant les données obtenues grâce à l'indice WQI avec des approches statistiques avancées, nous pourrions mieux comprendre les relations complexes entre les différents facteurs qui influent sur la qualité de l'eau dans notre contexte d'étude. Ce chapitre représentera une avancée significative dans notre compréhension de la dynamique de la pollution de l'eau et fournira des indications précieuses pour la mise en œuvre de mesures correctives.

**Chapitre V : Identification des variables d'entrées par
l'analyse en composante principale (ACP) et Gamma
test (GT)**

1. Introduction

Le but de ce chapitre est d'établir une approche méthodologique permettant de choisir judicieusement les variables d'entrée qui rentrent dans le processus de modélisation par les techniques de l'IA où la sélection des variables d'entrée est d'une importance cruciale. C'est cette sélection initiale qui va fortement influencer les performances et la robustesse des résultats obtenus.

2. Application de l'analyse en composante principale (ACP)

2.1. Présentation de l'ACP

L'ACP est une méthode de statistiques descriptives multivariée. Elle a été initialement introduite par (Pearson 1901) au début du XXe siècle, puis développée par (Hotelling (1933) et par Jean-Paul Benzecri durant les années 1960. Elle permet de représenter statistiquement et géométriquement les données en prenant un tableau contenant les valeurs de p variables (mesurées) pour un ensemble de n individus (Baccini 2010; DUBY and Robin 2006).

Elle est largement reconnue pour obtenir des informations significatives d'une base de données. Elle permet également d'explorer et mettre en évidence les corrélations entre les variables, avec pour objectif de réduire les dimensions d'une population tout en préservant au mieux l'information essentielle (Kouadri, Kateb, and Zegait 2021). L'ACP représente les facteurs dans un contexte bi ou tridimensionnel pour identifier des classes d'observation uniformes ou, à l'inverse, aberrantes et cela réduit le nombre de facteurs tout en gardant les faits (Elemile et al. 2021; Nguyen and Huynh 2022; de Souza et al. 2021; Tripathi and Singal 2019). Dans cette étude, l'ACP est utilisée afin de déterminer les liens (relations) entre les variables physicochimiques et WQI, dans l'optique de sélectionner les composantes qui ont une corrélation significative avec WQI et de les exploiter comme éléments d'entrée lors de la création du modèle (étape d'apprentissage).

Les premiers résultats à présenter sont les statistiques descriptives puis la répartition de l'inertie totale à travers les différentes composantes principales pour les sept variables objet de la présente étude.

2.2. Statistiques descriptives

Les statistiques permettent de synthétiser les caractéristiques essentielles des variables étudiées, offrant ainsi une vision d'ensemble de leur distribution et de leur variabilité.

Dans notre étude, nous avons utilisé les statistiques descriptives comme outil initial pour explorer les données relatives aux variables physico-chimiques de l'eau. Ces données sont non seulement importantes pour comprendre la qualité de l'eau, mais aussi pour vérifier si elle respecte les normes établies par des organismes gouvernementaux tels que JORA (2006) et SEQ-Eau (2003). En comparant les valeurs obtenues avec ces normes, nous pouvons mesurer le degré de conformité de l'eau échantillonnée, cela est crucial pour prendre des décisions éclairées concernant la gestion de l'eau et la préservation de l'écosystème.

Dans le **tableau V.1**, nous présentons un résumé des principales statistiques descriptives pour chaque paramètre physico-chimique étudié. Ces statistiques comprennent la moyenne, qui représente la tendance centrale des données, ainsi que le minimum et le maximum, qui fournissent des informations sur l'étendue des valeurs observées. De plus, l'écart type (ET) est également présenté, fournissant une évaluation de la répartition des données autour de la moyenne.

Tableau V.1. Résumé des statistiques descriptives des paramètres physicochimiques

Variables	Saisons	Taille N	Moy	Min	Max	ET
pH	Automne	209	7.67	7.00	8.40	0.32
	Hiver	221	7.54	6.70	8.20	0.31
	Printemps	171	7.61	6.90	8.40	0.32
	Été	162	7.90	7.00	8.50	0.40
T	Automne	209	27.66	18.00	38.00	4.18
	Hiver	221	21.66	14.00	30.10	3.16
	Printemps	171	24.98	9.00	36.00	3.67
	Été	162	31.44	21.60	38.00	3.66
CE	Automne	209	1073.15	607.00	1920.00	328.91
	Hiver	221	1158.88	475.00	3000.00	463.71
	Printemps	171	1094.14	595.00	2770.00	549.95
	Été	162	972.87	559.00	1778.00	249.87
PO ₄	Automne	209	0.85	0.06	3.00	0.50
	Hiver	221	0.68	0.06	4.91	0.55
	Printemps	171	0.82	0.05	2.38	0.52
	Été	162	0.87	0.03	3.86	0.57
DCO (mg d'O ₂ /l)	Automne	209	3.35	0.15	9.80	1.58
	Hiver	221	3.68	0.10	38.40	3.72
	Printemps	171	3.21	0.20	9.60	1.70
	Été	162	2.89	0.50	9.90	1.41
CxHy	Automne	209	0.11	0.00	0.80	0.12
	Hiver	221	0.08	0.00	1.10	0.11
	Printemps	171	0.08	0.00	0.62	0.07
	Été	162	0.07	0.00	0.32	0.06
WQI	Automne	209	25.95	7.33	44.03	7.72
	Hiver	221	20.61	0.67	35.66	7.25
	Printemps	171	23.62	8.45	41.26	7.83
	Été	162	32.07	8.57	49.13	9.23

Les moyennes de pH, en général, se situent dans une plage allant de 6,5 à 8,5. Tout écart par rapport à ces valeurs normales peut souvent indiquer l'existence de polluants ou d'autres éléments nocifs dans l'eau. Dans notre étude, les échantillons prélevés dans la région d'étude ont révélé des caractéristiques de pH se situant dans une plage neutre à légèrement basique. La valeur maximale enregistrée, atteignant 8,5 en été, garantit une stabilité relative du pH, tandis que la valeur minimale enregistrée, de 6,70 en hiver, reste dans des limites acceptables. En moyenne, le pH

observé est de 7,68, ce qui confirme une certaine stabilité de la qualité de l'eau de la STEP (voir **figure V.1**).

Par ailleurs, la température moyenne des échantillons d'eau se situe autour de 26,43 °C, ce qui est considéré comme optimal pour favoriser les processus d'épuration biologique et d'autoépuration des rejets (Abbas Merghem et al. 2016). Cette température modérée, restant en dessous de 30 °C, est propice au maintien de l'équilibre biologique dans les écosystèmes aquatiques. Les variations saisonnières de température enregistrées dans la région d'étude, avec une valeur minimale de 9 °C au printemps et une valeur maximale de 30 °C en été, restent néanmoins dans des limites acceptables selon les normes établies par JORA (2006), ce qui indique que ce rejet ne présente aucun risque sur l'environnement (voir **figure V.1**).

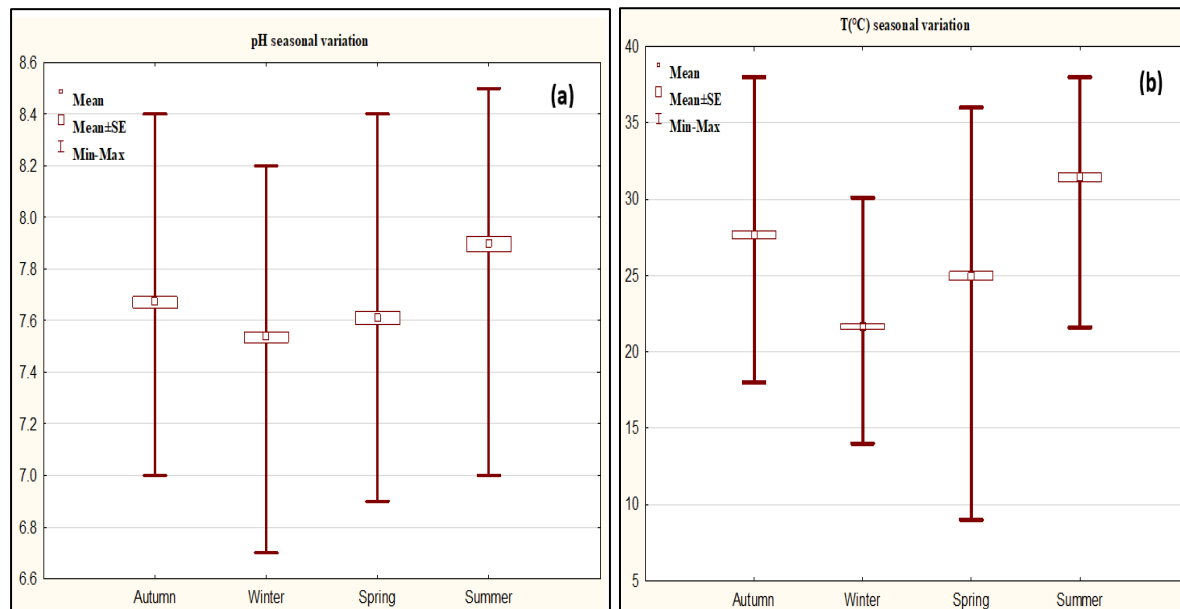


Figure V.1. Variations saisonnières du pH et la température de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.

D'après Rodier et al. (2009), la conductivité offre une estimation du niveau de minéralisation de l'eau, car la majorité des substances dissoutes dans l'eau se présentent sous forme d'ions électriquement chargés. (Chaouay et al. 2016).

Dans notre analyse, les valeurs de la CE observées pendant la période de d'observation ont varié de manière significative, avec un minimum de 475 $\mu\text{S}/\text{cm}$ et un maximum de 3000 $\mu\text{S}/\text{cm}$ enregistrés en hiver. La moyenne calculée s'élève à 1074,76 $\mu\text{S}/\text{cm}$, une valeur qui reste dans une fourchette généralement considérée comme acceptable, située entre 180 et 3000 $\mu\text{S}/\text{cm}$. Cette plage de valeurs permet de classer l'eau étudiée dans la classe 1 de très bonne qualité selon les normes établies par SEQ-Eau (2003). De ce fait, ces niveaux de conductivité n'indiquent aucun danger pour l'environnement lors du déversement de cette eau.

En ce qui concerne les concentrations de phosphate (P-PO_4), les résultats obtenus dans notre **tableau V.1** présentent des fluctuations saisonnières significatives, avec des valeurs allant d'un minimum de 0,06 mg/l en été à un maximum de 4,91 mg/l en hiver. Malgré ces fluctuations, la moyenne observée reste relativement faible, à 0,80 mg/l. Ces concentrations respectent largement les normes de rejets établies à 10 mg/l par JORA (2006), ce qui assure la performance du purification biologique mis en place au niveau de la STEP de la raffinerie (RA1K). En effet, cette faible teneur en ortho-phosphate est généralement attribuable à la transformation des Organo-phosphates en poly-phosphates et ortho-phosphates par l'activité microbienne au sein du système de traitement biologique.

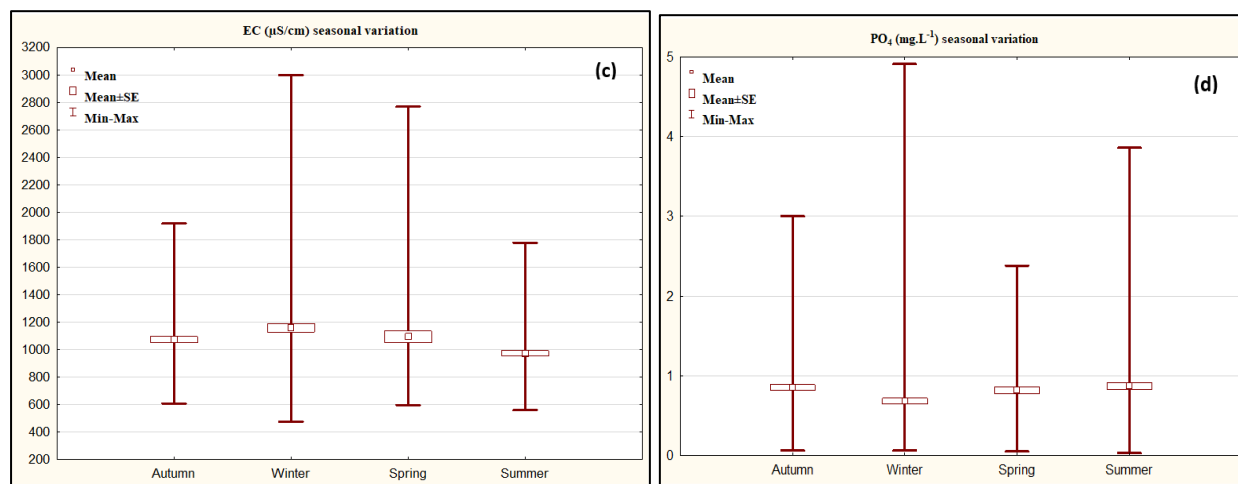


Figure V.2. Variations saisonnières de la CE et PO_4 de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.

L'indicateur DCO affecte généralement 60 à 70 % des substances organiques, y compris celles qui ne sont pas biodégradables (Iticescu et al. 2016).. Dans notre étude, les valeurs moyennes de DCO ont atteint environ $3.28 \text{ mg O}_2\text{L}^{-1}$. La variation saisonnière est significative, avec un minimum de $0,1 \text{ mg O}_2\text{L}^{-1}$ enregistrée et un maximum de $38,4 \text{ mg O}_2\text{L}^{-1}$ observée en hiver. Cependant, même avec cette variation, la valeur moyenne reste inférieure à la norme établie par JORA (2006), fixée à $120 \text{ mg O}_2\text{L}^{-1}$. Ces résultats suggèrent une charge organique relativement faible dans les échantillons d'eau étudiés, ce qui est encourageant du point de vue de la qualité de l'eau.

Quant aux teneurs en hydrocarbures totaux (CxHy), elles sont également examinées dans notre étude. Durant toute la durée d'observation, ces teneurs restent très faibles, variant de zéro pour toutes les saisons à un maximum de $1,1 \text{ mg. L}^{-1}$ enregistré en hiver. La moyenne est de $0,09 \text{ mg. L}^{-1}$, ce qui est significativement en deçà de la limite de 10 mg. L^{-1} fixée par JORA (2006). Ces résultats confirment l'efficacité du pouvoir épuratoire de la STEP de la raffinerie de Skikda.

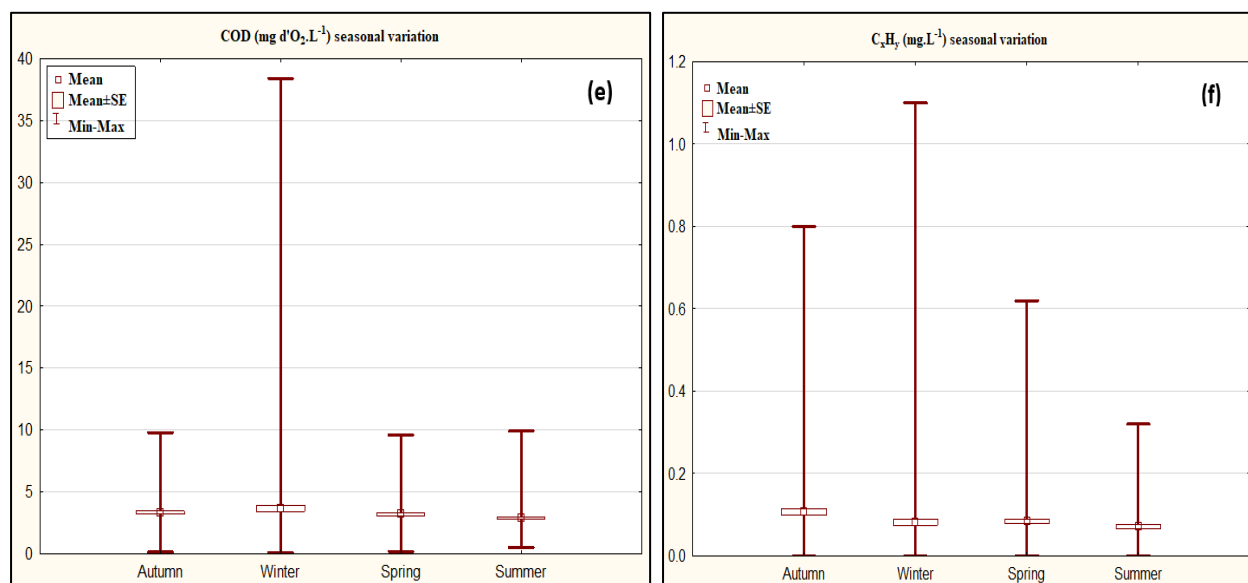


Figure V.3. Variations saisonnières de la DCO et CxHy de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.

Dans notre étude, la valeur moyenne du WQI, comme indiqué dans le tableau II.1, tourne autour de 25,56, dont la variation saisonnière est significative, avec une valeur minimale de 0,67 observée en hiver, et une valeur maximale de 49,13 enregistrée en été.

Selon les critères de classification de Lepper (2005), ces valeurs permettent de classer l'eau étudiée comme étant de bonne à très bonne qualité. En effet, les valeurs comprises entre 26 et 50 correspondent à une bonne qualité d'eau, tandis que celles entre 0 et 25 indiquent une eau de très bonne qualité avec une répartition sur la totalité des échantillons de 51 % pour la bonne qualité et de 49 % pour la très bonne qualité.

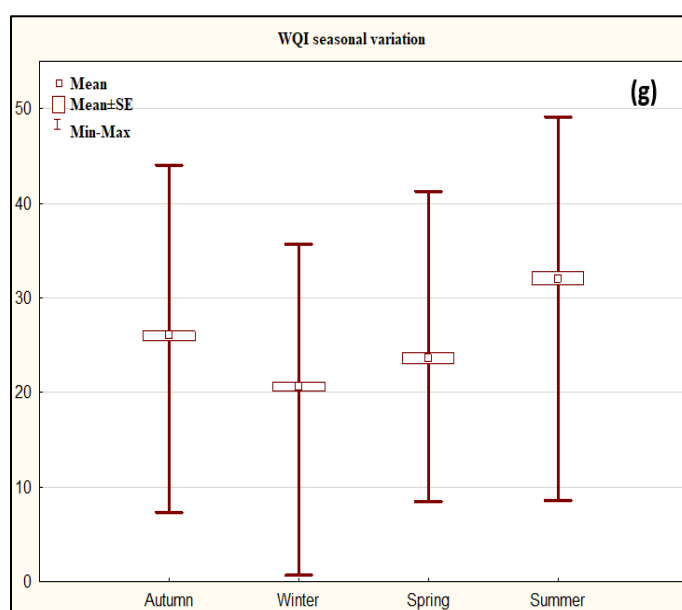


Figure V.4. Variations saisonnières de WQI de l'eau traitée par la STEP du complexe de raffinage de pétrole de Skikda.

L'analyse des variables physico-chimiques des effluents traités à la STEP de la raffinerie de Skikda (RA1/K) révèle que ces rejets répondent aux normes établies par JORA (2006), ce qui confirme leur aptitude à être déversés en toute sécurité dans l'Oued Marhoum. Cette observation met en évidence la fiabilité et l'efficacité du processus d'épuration adopté.

2.3. Identification des variables de qualité de l'eau par l'ACP

L'ACP a été utilisée pour visualiser la structuration des données à la sortie de la STEP.

La répartition de l'inertie des données est représentée par les valeurs propres (λ) et le taux d'explication en pourcentage (%). Les valeurs propres évaluent la quantité de variance expliquée par chaque composante principale, tandis que le taux d'explication indique la proportion totale de variance expliquée par l'ensemble des composantes principales. Dans notre analyse, la somme des valeurs propres est égale au nombre total de variables incluses dans l'analyse, soit 7 variables. Les trois premières composantes principales, qui décrivent les trois dimensions principales des données, ont été retenues. Ensemble, elles expliquent une inertie totale de 65,011% de l'inertie totale avec une somme des valeurs propre de l'ordre de (4.550).

La première valeur propre, représentant la variance expliquée par la première composante principale (CP1) avec $\lambda_1=2.488$, ce qui correspond à un taux de variance expliquée de 35.547 % de la variance totale. Elle prend donc l'axe dominant et représente le maximum d'information.

La deuxième composante principale, quant à elle, possède la deuxième plus grande valeur propre, avec $\lambda_2=1.052$, représentant un taux de variance de 15.035 %. Il est essentiel de noter que la deuxième composante principale (CP2) prend le maximum d'information une fois que la première composante principale (CP1) est prise en compte. En combinant CP1 et CP2, ces deux premières composantes principales représentent ensemble 50.583 % de la variance totale.

La troisième composante principale (CP3) a la troisième plus grande valeur propre, $\lambda_3=1.009$, représentant un taux de variance de 14.427 % de la variance totale. Il est important de souligner que CP3 représente le maximum d'information une fois que CP1 et CP2 sont pris en considération, et que sa variance est maximisée sous la contrainte qu'elle ne soit pas corrélée avec CP1 et CP2. En combinant CP1, CP2 et CP3, ces trois premières composantes principales représentent 65.011 % de l'inertie totale des données (**Tableau V.2**).

Tableau V.2. Répartition des valeurs propres (Eigenvalues)

	Valeur propre (λ)	% Total variance	Cumulative Eigenvalue	Cumulative %
CP1	2.488320	35.54742	2.488320	35.5474
CP2	1.052488	15.03554	3.540807	50.5830
CP3	1.009945	14.42779	4.550752	65.0107
CP4	0.942751	13.46787	5.493503	78.4786
CP5	0.841281	12.01830	6.334784	90.4969
CP6	0.665216	9.50308	7.000000	100.0000

L'extraction des composantes principales se poursuit jusqu'à ce qu'il y ait autant de composantes principales que de variables, dans le but de tenir le maximum d'information tout en réduisant la dimensionnalité des données. L'ACP fournit des statistiques intéressantes, spécifiquement les coefficients de corrélation entre les différentes variables et les composantes principales, également connus sous le nom de vecteurs de pondération, liés à chaque composante principale individuellement (**Tableau V.3**) et les contributions des variables à la formation de ces composantes principales (**Tableau V.4**).

Les vecteurs de pondération indiquent l'importance relative de chaque variable originelle dans la variance de la composante principale correspondante, ou la part des variations des variables originelles expliquées par les composantes principales. Les corrélations entre les variables et les composantes principales sont proportionnelles aux éléments des vecteurs de pondération associés.

Chaque CP correspond à une combinaison linéaire des variables d'origine. Dans notre étude, la première CP, représentée dans le premier axe du plan factoriel [1,2], montre une forte association avec le pH, la température (T) et WQI, avec des coefficients de corrélation dépassant 0.60. En revanche, la conductivité électrique (CE) et la teneur en phosphate (PO_4) contribuent faiblement à cette première composante principale. Enfin, la DCO et les hydrocarbures totaux (C_xH_y) ne contribuent pas à la formation de la CP1.

La deuxième composante principale est généralement définie par les variables qui ne sont pas pris en considération par la première composante principale. A partir du (**Tableau V.3**), on remarque que la CE, PO_4 et C_xH_y ont des coefficients de corrélation les plus élevés et en

particulier la concentration en hydrocarbures (CxHy) avec un coefficient de corrélation de (0.731).

Quant à la troisième composante principale, elle continue à extraire le reste de l'information une fois la première et la deuxième sont prise en considération. Dans ce sens, elle prend en considération uniquement une seule variable, la COD qui n'a pas été représentée au niveau de la première et la deuxième composante avec un coefficient de corrélation de (0.325101).

Tableau V.3. Représentation des coefficients de corrélations entre les composantes principales et les différentes variables.

Variables	F 1	F 2	F 3
pH	-0.896	-0.0009	-0.1640
T (°C)	-0.665	-0.1018	0.1718
CE (µS/cm)	0.348	0.3459	0.1991
PO₄ (mg/l)	-0.395	0.6026	0.1738
DCO (mg/l)	0.141	-0.0937	0.3251
CxHy (mg/l)	0.069	-0.7316	-0.3181
WQI	-0.968	0.0377	-0.1130

Etant donné que les variables d'origine (7 variables) sont linéairement corrélées avec les différentes composantes principales et que leurs coefficients de corrélation varient d'une composante à l'autre, la contribution de la variable à la formation de la composante varie aussi dans le même sens. Les contributions des variables étudiées à la formation de différentes composantes principales sont présentées dans le **Tableau V.4**. Nous remarquons que le pH, T et WQI ont la plus grande part de contribution à la formation de la première composante principale CP1 avec 87.83 % de la somme totale. Tandis que la CE, PO₄ et CxHy contribuent à la formation de la composante principale CP2 avec 93.62%. Alors que la troisième composante principale CP3 reçoit la plus grande contribution de la variable DCO avec une contribution totale de 26.92%.

Tableau V.4. Contributions des variables à la formation des différentes composantes principales

Variables	F 1	F 2	F 3
pH	0.323	0.000001	0.0266
T (°C)	0.178	0.0098	0.0292
CE (µS/cm)	0.049	0.2043	0.0797
PO₄ (mg/l)	0.063	0.2233	0.0854
DCO (mg/l)	0.008	0.0525	0.2692
CxHy (mg/l)	0.002	0.5086	0.0971
WQI	0.377	0.0013	0.0226

2.4. Matrice de corrélation

De plus, l'examen de la matrice de corrélation, illustrée dans le tableau II.5, révèle que parmi ces paramètres, seuls trois présentent une forte corrélation ($> 0,9$) avec le WQI : le pH, la température (T), et la concentration en hydrocarbures (CxHy), avec des coefficients de corrélation respectifs de 0,937, 0,987, et 0,993. En outre, il est mentionné qu'une corrélation moyenne de 0.545 est observée avec le phosphate (PO₄).

Ces corrélations mettent en évidence que le pH, la température, la teneur en hydrocarbures et le phosphate sont les principales variables influençant la qualité de l'eau épurée au niveau de la station d'épuration de la raffinerie de Skikda avant son rejet dans l'environnement. Par conséquent, ces variables sont sélectionnées comme entrées dans les modèles de réseaux de neurones artificiels (ANN) en raison de leur forte corrélation avec WQI.

Tableau V.5. Matrice de corrélations

Variables	pH	T (°C)	CE	PO4	DCO	CxHy	WQI
pH	1						
T	0.972	1					
CE	0.914	0.979	1				
PO4	0.492	0.518	0.536	1			
DCO	0.734	0.850	0.927	0.447	1		
CxHy	-0.091	-0.043	-0.034	-0.335	-0.053	1	
WQI	0.937	0.987	0.099	0.546	0.291	-0.993	1

3. Application de la technique de Gamma test (GT)

Traditionnellement, le développeur des modèles doit faire recours à plusieurs essais pour sélectionner la meilleure parmi plusieurs combinaisons des variables d'entrées (les inputs), puisqu'il n'a pas une idée précise sur la meilleure structure possible. Cette démarche consomme beaucoup de temps, puisque on doit calibrer et par la suite tester (valider) différents modèles avec différentes structures. Par exemple si nous avons 6 entrées (pH, T, CE, PO₄, DCO et CxHy) nous aurons (2^6-1) donc 63 combinaisons possibles (i.e. 63 modèles) à tester pour déterminer le meilleur modèle. La technique GT peut réduire considérablement le travail à effectuer pour le développement des modèles et fournit un guide pour la sélection des entrées avant le développement des modèles. Fondamentalement, la technique GT est capable de fournir la meilleure MSE que tout autre modèle peut garantir. Dans le présent travail, différentes combinaisons des variables d'entrée ont été testées pour étudier leur influence sur WQI, et la meilleure combinaison est déterminée en observant la valeur de Gamma (Γ).

Etant donné que nous avons utilisés six (6) variables comme entrées des modèles, nous utiliserons par la suite le terme « MASK » pour identifier la structure ou bien la configuration du modèle. Les 6 variables doivent être présentées en ordre de 1 à 6 (**Tableau V.6**). Un MASK prend une forme numérique formée de 6 chiffres et contenant uniquement le 1 ou le zéro (1 ou 0), le 1 indique que la variable est incluse et le 0 indique que la variable est exclue.

Tableau V.6. Agencement des différentes variables

Variable	pH	T	CE	PO ₄	DCO	CxHy
Ordre	1	2	3	4	5	6

Étant donné que nous disposons de 6 variables d'entrée (pH, T, CE, PO₄, DCO et CxHy), cela nous conduit à considérer 6 types de modèles : des modèles utilisant une, deux, trois, quatre, cinq et six variables d'entrée respectivement. Parmi ceux-ci, nous avons sélectionné trois modèles principaux (M4, M5 et M6). Chaque modèle a été évalué selon plusieurs scénarios, et nous avons retenu les modèles offrant les valeurs les plus faibles de Gamma (Γ) sous forme de MASQUE, qui spécifie les variables à considérer et celles à écarter. **Le tableau V.7** expose la classification des différents modèles d'entrée en fonction des valeurs de Gamma (Γ).

Tableau V.7. Classification des différents modèles d'entrée selon la valeur de Gamma (Γ).

N° de modèle	Gamma (Γ)	Standard Error (SE)	V-ratio	Masque	Variables d'entrée
M4	0.000498254	0.057851045	0.00139852	110101	pH, T, PO ₄ , C _x H _y
M5	0.001789049	0.057351886	0.001231805	110111	pH, T, PO ₄ , DCO, C _x H _y
M6	0.002184719	0.082842394	0.00120171	111111	pH, T, CE, PO ₄ , DCO, C _x H _y

D'après les données présentées dans le **Tableau V.7**, nous avons retenus que trois modèles principaux : le premier (M4) utilise quatre variables d'entrée, le deuxième (M5) en utilise cinq, tandis que le troisième modèle (M6) utilise la totalité des variables disponibles. Une observation importante est que les trois modèles sélectionnés incluent systématiquement les quatre variables pH, température (T), concentration en phosphate (PO₄), et la concentration en hydrocarbures (C_xH_y). Cette sélection reflète notre démarche visant à maximiser la pertinence des données utilisées pour la prédiction du WQI, en accordant une attention particulière à ces quatre variables qui présentent une corrélation significative avec le WQI, comme indiqué précédemment.

De plus, la combinaison (M4) avait la valeur la plus faible des statistiques de Gamma ($\Gamma = 4.98 \cdot 10^{-4}$, V-ratio = 0.0578 et Masque = 110101)

Ce masque montre une intégration acceptable en termes de nombre de facteur explicatif (paramètre d'entrée), de sorte que ces variables d'entrée seront utilisées comme entrées pour les modèles ANN pour la prévision de WQI à pas de temps saisonnier.

L'incorporation de ces quatre facteurs explicatifs dans le modèle (M4) est également cohérente avec notre objectif de simplification tout en maintenant un niveau élevé de précision dans la prédiction du WQI. Cette méthode garantit une représentation adéquate des facteurs influençant la qualité de l'eau tout en évite la surcharge de données et la complexité excessive du modèle.

4. Conclusion

En se référant aux conclusions issues de l'ACP et GT, nous avons retenu un seul modèle (M4) qui sera employé dans la modélisation par les ANN ayant comme entrées (pH, T, PO₄, CxHy) et le WQI comme sortie. En utilisant ces variables sélectionnées dans les modèles ANN, nous visons à améliorer la précision des prédictions du WQI, nécessaires à la gestion et la préservation des ressources en eau.

Chapitre VI : Méthode de surface de réponse (RSM)

1. Introduction

Ce chapitre se consacre à la méthodologie RSM (Response Surface Methodology), une approche puissante permettant de simuler des relations complexes et interactives entre plusieurs variables, offrant une perspective novatrice en matière de prédiction, ce qui peut conduire à des prédictions plus précises (Wang et al. 2022). L'un des avantages fondamentaux de cette méthode est qu'elle permet une optimisation systématique des paramètres physico-chimiques. Grâce à une conception expérimentale efficace, l'approche RSM peut identifier les valeurs idéales des facteurs qui conduisent à un traitement amélioré de la qualité de l'eau, réduisant ainsi les coûts et augmentant l'efficacité du traitement et peut être utilisées pour optimiser les relations complexes entre de nombreux paramètres.

2. Matériel et méthodes

Pour réaliser la méthode RSM (Réponse de Surface Méthodique) sur la qualité de l'eau de la station d'épuration des eaux usées de la raffinerie, nous avons utilisé le logiciel Design-Expert (version : 11.1.2.0). Nous avons opté pour le modèle de plan expérimental Box-Behnken (BBD), qui est bien adapté à notre objectif de recherche. Dans ce plan expérimental, nous avons identifié quatre facteurs clés, notés A, B, C et D, qui correspondent respectivement au pH, à la température (T), au phosphate (PO_4^{3-}) et aux hydrocarbures totaux (CxHy), en tant que paramètres d'entrée. Le paramètre de réponse, noté E, représente l'indice de qualité de l'eau (WQI).

Le plan expérimental RSM/BBD a été conçu pour inclure 29 séries expérimentales, réparties de manière aléatoire. Chacune de ces séries expérimentales a été définie avec des niveaux de faible (-1), moyen (0) et élevé (+1) pour les variables d'entrée mentionnées dans le **Tableau VI.1**. Ce plan expérimental nous permettra d'explorer et d'analyser de manière exhaustive l'impact des différents niveaux de ces paramètres sur la qualité de l'eau de la station d'épuration.

Tableau VI.1. Développement des niveaux de test

Variables	Units	Symbol	Type	Levels											
				Autumn			Winter			Spring			Summer		
				Min (-1)	Medium (0)	Max (+1)	Min (-1)	Medium (0)	Max (+1)	Min (-1)	Medium (0)	Max (+1)	Min (-1)	Medium (0)	Max (+1)
pH	%	A	Numeric	7.2	7.6	7.8	6.7	7.5	8.1	7.0	7.5	8.1	7.0	8.0	8.7
Temperature	°C	B	Numeric	23	27	31	16	20	27	19	26	31	22	28	34
PO ₄	mg/l	C	Numeric	0.1	0.8	2.2	0	0.9	4.9	0.2	1.0	2.1	0.2	0.9	1.8
CxHy	mg/l	D	Numeric	0	0.1	0.7	0	0.1	0.2	0	0.1	0.4	0	0.1	0.2

Pour évaluer l'efficacité du traitement d'épuration des eaux usées de la raffinerie, les indices de qualité de l'eau pour les quatre saisons (automne, hiver, printemps et été) ont été étudiés. Ces indices, notés WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} , ont été examinés pour déterminer comment les interactions entre les variables influent sur l'efficacité globale du traitement.

Pour réduire les erreurs systématiques et minimiser l'impact des variations inconnues sur les réponses mesurées, toutes les expériences ont été réalisées de manière aléatoire, conformément à la méthode proposée par (Liang et al. 2023). Cette approche permet d'obtenir des données robustes et fiables, reflétant de manière précise les interactions entre les différentes variables du processus de traitement des eaux usées.

Les résultats expérimentaux ont été ajustés à l'aide d'un modèle du second ordre, représenté par l'équation de régression (Eq. (1)). Cette équation de régression permet de quantifier l'effet de chaque variable sur les indices de qualité de l'eau et de déterminer les interactions significatives entre les variables. De plus, des visualisations en 3D de la surface de réponse ont été générées pour mieux comprendre la relation entre les variables d'entrée et les réponses mesurées, offrant ainsi un aperçu visuel de la performance du système de traitement dans différentes conditions environnementales tout au long de l'année.

$$Y = B_0 + \sum_1^n B_i X_i + \sum_1^n B_{ij} X_i X_j + \sum_1^n B_{ii} X_i^2 \quad (1)$$

Où Y représente la réponse attendue, n est le nombre total de tests expérimentaux, et β_0 , β_i , β_{ii} et β_{ij} sont les coefficients de régression correspondant aux termes fixe, linéaire, quadratique et interactif, respectivement.

- Le coefficient β_0 est associé au terme fixe de l'équation de régression, représentant l'effet moyen de tous les facteurs lorsque les variables d'entrée sont à leur niveau zéro.
- Les coefficients β_i quantifient l'effet linéaire de chaque variable d'entrée sur la réponse. Ils mesurent comment un changement d'une unité dans la variable d'entrée affecte la réponse, toutes choses étant égales par ailleurs.
- Les coefficients β_{ii} expriment l'effet quadratique de chaque variable d'entrée sur la réponse. Ils capturent les effets de courbure ou de non-linéarité dans la relation entre la variable d'entrée et la réponse.
- Les coefficients β_{ij} représentent les termes interactifs, c'est-à-dire les effets combinés de deux variables d'entrée sur la réponse. Ils montrent comment les interactions entre différentes variables influencent la réponse, ce qui peut être crucial pour comprendre le comportement global du système.

3. Résultats et discussion

3.1. Analyse de la variance (ANOVA)

La fonction BBD du logiciel Design-Expert a été employée pour évaluer le modèle RSM, en considérant les facteurs d'entrée cubiques, linéaires et quadratiques pour caractériser la relation entre la réponse et les interactions à deux facteurs (2FI). Les modèles appropriés ont été choisis en utilisant un critère de $P < 0,05$ et des valeurs de coefficient de corrélation proches de 1, indiquant une bonne adéquation entre le modèle et les données observées.

Les ajustements statistiques ont confirmé la validité des modèles quadratiques pour WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} , avec des coefficients de corrélation ajustés (R^2) significatifs ($P < 0,05$) de 0,9279, 0,8757, 0,9605 et 0,9732 respectivement. En outre, les valeurs de R^2 prédit, mesurant la capacité du modèle à expliquer la variance autour de la moyenne, se sont avérées satisfaisantes avec des valeurs de 0,6587, 0,6464, 0,8699 et 0,8450 respectivement, se situant à moins de 0,2 de la limite de signification du modèle pour une prédiction sans erreur.

L'analyse de variance (ANOVA) a mis en évidence les termes significatifs, avec des P-values inférieures à 0,05, notamment les facteurs interactifs, linéaires et quadratiques (voir **Tableau VI.2**). Les valeurs F illustrent l'importance relative de ces termes, tandis que les P-values confirment la pertinence des résultats des modèles de régression, conforme aux travaux antérieurs (Abdulredha et al., 2020 ; Sibiya et al., 2022). L'analyse de probabilité de P-value a été réalisée avec un niveau de confiance de 95%.

Bien que certaines variables aient présenté des P-values supérieures à 0,05 et n'aient donc pas été considérées comme significatives, elles ont tout de même été incluses dans le modèle afin d'évaluer leur contribution potentielle et leur prévisibilité, avec pour critère que le R^2 soit supérieur à 0,95.

Tableau VI.2. Analyse de la variance (ANOVA) de l'indice de qualité des eaux usées traitées à la raffinerie à pas de temps saisonnier.

Source	Sum of squares	df	Mean square	F-value	p-Value	
WQI_{AUT}						
Model	679.6079	14	48.5434	12.8716	<0.0000	Significant
A-pH	13.4357	1	13.4357	3.5626	0.08	
B-T	15.1126	1	15.1126	4.0072	0.0651	
C-PO4	73.4087	1	73.4087	19.4649	0.0006	
D-CxHy	7.4036	1	7.4036	1.9631	0.183	
AB	6.6483	1	6.6483	1.7629	0.2055	
AC	0.8104	1	0.8104	0.2149	0.6501	
AD	192.9492	1	192.9492	51.1619	0	
BC	3.1735	1	3.1735	0.8415	0.3745	
BD	14.5459	1	14.5459	3.8569	0.0697	
CD	0.2033	1	0.2033	0.0539	0.8198	
A2	59.8771	1	59.8771	15.8769	0.0014	
B2	140.1522	1	140.1522	37.1624	0	
C2	80.9963	1	80.9963	21.4768	0.0004	
Residual	52.8	14	3.77			
Lack of fit	46.51	10	6.5421	2.5471	0.2654	Not significant
Cor Total	732.41	28				
Fit Statistic	Std.Dev	1.14		R2	0.9279	
	Mean	24.97		Adjusted R2	0.8558	
	CV%	7.78		Predicted R2	0.6587	
				Adeq Precision	7.49.08	
WQI_{WIN}						
Model	1991.1103	14	142.2222	15.0856	0	Significant
A-pH	35.5111	1	35.5111	3.7667	0.0727	
B-T	1.2832	1	1.2832	0.1361	0.7177	
C-PO4	98.4831	1	98.4831	10.4461	0.006	
D-CxHy	52.631	1	52.631	5.5826	0.0331	
AB	0.0171	1	0.0171	0.0018	0.9666	
AC	0.0553	1	0.0553	0.0059	0.94	
AD	0.1141	1	0.1141	0.0121	0.914	
BC	3.0797	1	3.0797	0.3267	0.5767	
BD	0.6051	1	0.6051	0.0642	0.8037	
CD	53.3056	1	53.3056	5.6541	0.0322	
A2	11.2868	1	11.2868	1.1972	0.2924	
B2	0.9064	1	0.9064	0.0961	0.7611	
C2	0.2212	1	0.2212	0.0235	0.8804	
Residual	131.99	14	9.43			
Lack of fit	123.56	10	13.2926	3.2314	0.2126	Not significant
Cor Total	2123.1	28				
Fit Statistic	Std.Dev.	1.07		R2	0.9378	
	Mean	21.57		Adjusted R2	0.8757	
	CV %	8.24		Predicted R2	0.6464	

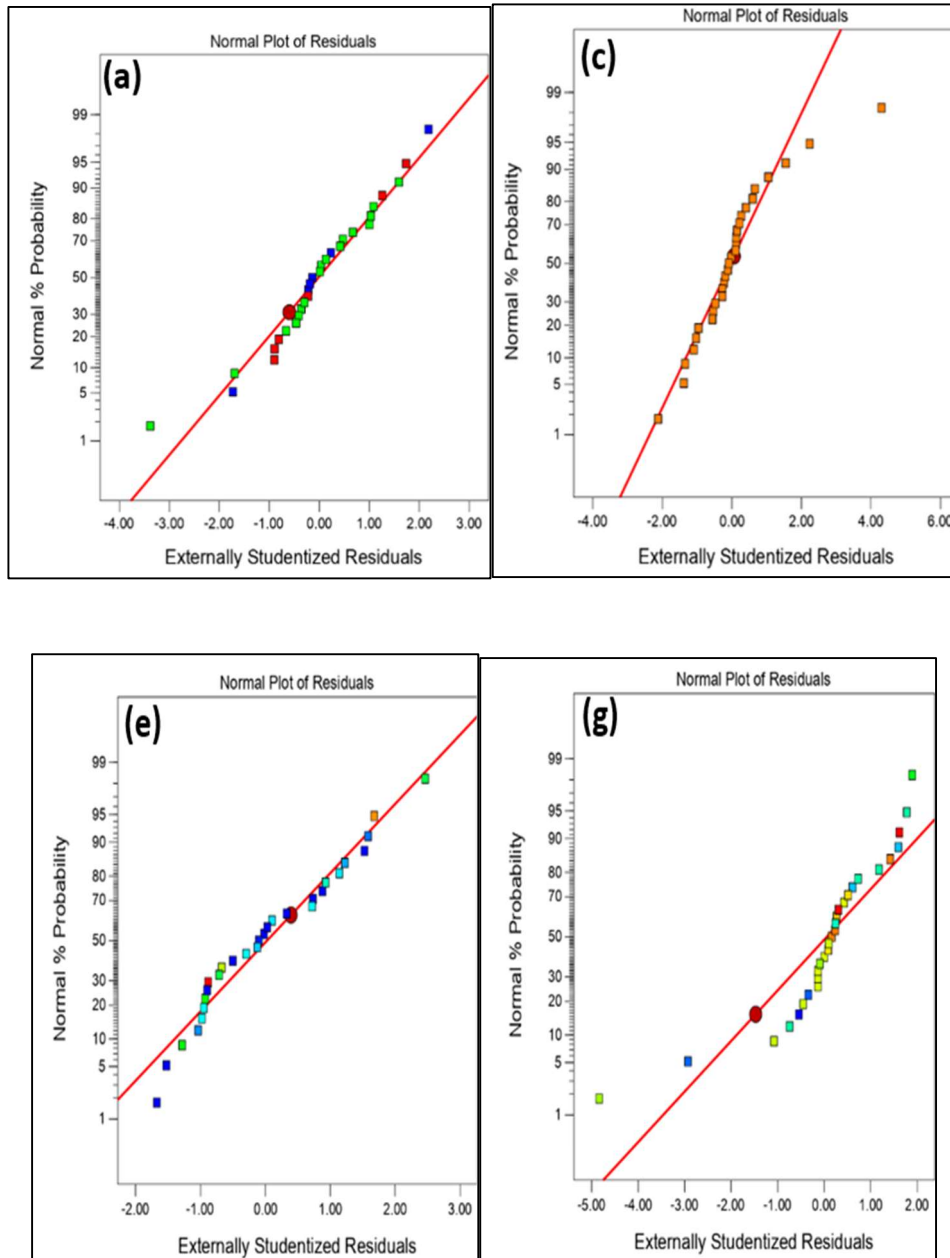
Chapitre VI. Méthode de surface de réponse (RSM)

				AdeqPrecision	15.987	
WQISPR						
Model	1201.2388	14	85.8028	49.5787	<0.0000	Significant
A-pH	68.0646	1	68.0646	39.3292	<0.0000	
B-T	0.0204	1	0.0204	0.0118	0.9152	
C-PO4	0.0489	1	0.0489	0.0282	0.869	
D-CxHy	0.0528	1	0.0528	0.0305	0.8638	
AB	1.1466	1	1.1466	0.6625	0.4293	
AC	0.0474	1	0.0474	0.0274	0.8709	
AD	0.3964	1	0.3964	0.229	0.6396	
BC	2.6502	1	2.6502	1.5314	0.2363	
BD	0.2336	1	0.2336	0.135	0.7188	
CD	1.5011	1	1.5011	0.8674	0.3675	
A2	0.1033	1	0.1033	0.0597	0.8105	
B2	0.1987	1	0.1987	0.1148	0.7397	
C2	0.1736	1	0.1736	0.1003	0.7561	
Residual	24.23	14	1.73			
Lack of fit	18.81	10	4.2654	4.1425	0.3125	Not significant
Cor Total	1225.47	28				
Fit Statistic	Std.Dev.	1.32		R2	0.9802	
	Mean	23.79		Adjusted R2	0.9605	
	CV%	5.53		Predicted R2	0.8699	
				AdeqPrecision	29.3015	
WQISUM						
Model	3766.1065	14	269.0076	73.4945	<0.0000	Significant
A-pH	415.7789	1	415.7789	113.5933	<0.0000	
B-T	9.5845	1	9.5845	2.6186	0.1279	
C-PO4	1.2318	1	1.2318	0.3365	0.5711	
D-CxHy	1.274	1	1.274	0.3481	0.5646	
AB	0.0023	1	0.0023	0.0006	0.9802	
AC	0.3537	1	0.3537	0.0966	0.7605	
AD	0.2169	1	0.2169	0.0593	0.8112	
BC	4.3424	1	4.3424	1.1864	0.2945	
BD	9.7183	1	9.7183	2.6551	0.1255	
CD	0.0999	1	0.0999	0.0273	0.8711	
A2	6.5767	1	6.5767	1.7968	0.2014	
B2	1.4627	1	1.4627	0.3996	0.5375	
C2	1.5677	1	1.5677	0.4283	0.5234	
Residual	51.24	14	3.66			
Lack of fit	44.56	10	5.1236	6.5223	0.3627	Not significant
Cor Total	Std.Dev.	0.98		R2	0.9866	
Fit Statistic	Mean	32.03		Adjusted R2	0.9732	
	CV%	5.97		Predicted R2	0.845	
				AdeqPrecision	28.9011	

De plus, le rapport signal/bruit calculé se situait dans la plage acceptable des points de conception, ce qui démontrait davantage l'utilité du modèle. Les proportions de précision, supérieures à 4, indiquent une bonne concordance entre les résultats expérimentaux et les valeurs prédites, avec des marges d'erreur réduites de 1,14, 1,07, 1,32 et 0,98 pour respectivement WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} . Ces résultats suggèrent que les modèles sont capables de reproduire et de prédire avec précision dans l'espace de conception, selon le coefficient de variation RSM (CV 10%) (Sibiya et al. 2022).

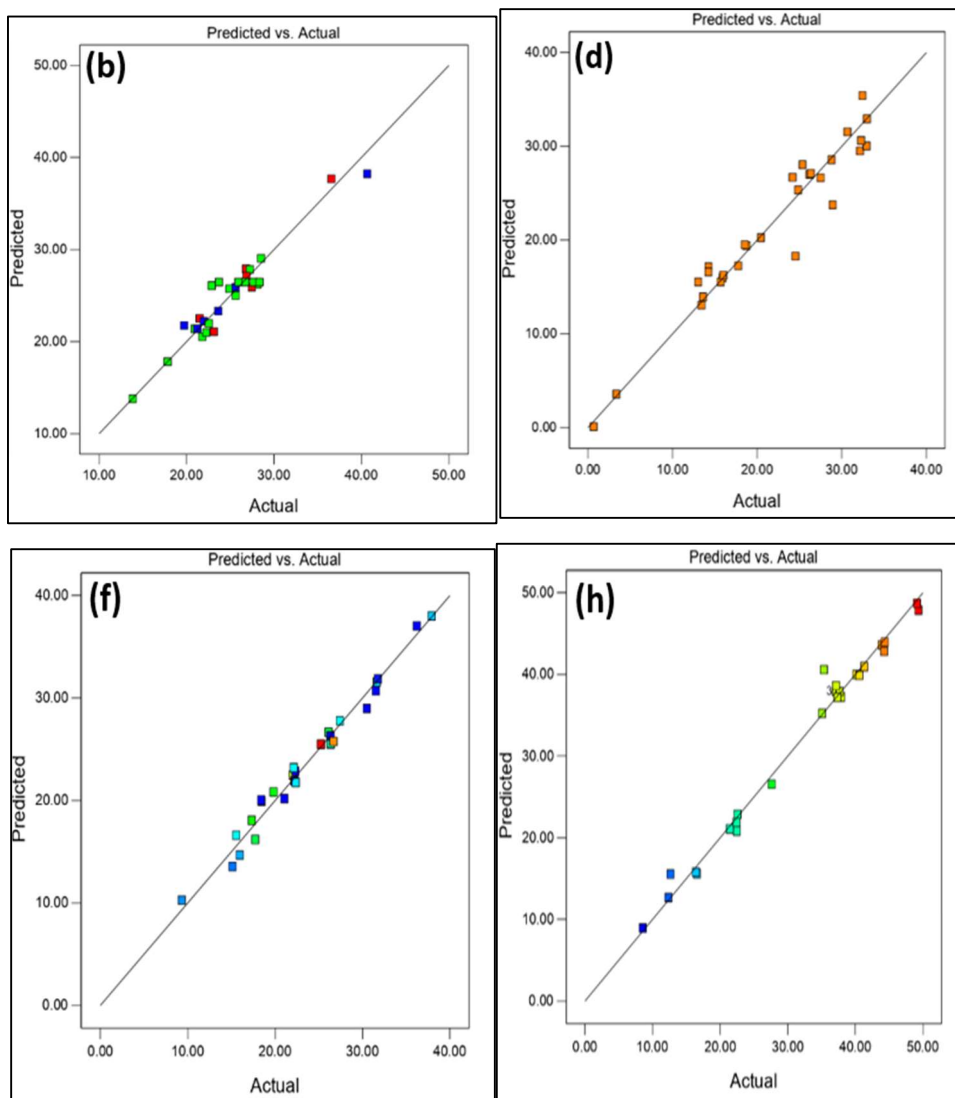
Le test F de Fisher a été utilisé pour évaluer la signification du modèle ainsi que l'importance de chaque variable d'entrée indépendante. Les valeurs $P < 0,05$ confirment l'acceptation du modèle quadratique. L'influence relative des variables a été révélée en comparant les valeurs des facteurs, où des coefficients positifs dénotent une harmonie et des coefficients négatifs indiquent une opposition. Les variables les plus cruciales ont été identifiées, telles que C, AD, A^2 , B^2 et C^2 pour WQI_{AUT} et C, D, CD et D^2 pour WQI_{WIN} . Certaines variables se sont avérées non significatives pour certains termes, ce qui a permis de mettre en lumière les éléments essentiels dans l'évaluation de la qualité de l'eau pour chaque saison.

Les points de données des **figures VI.1** ont été disposés à la fois à l'intérieur et à l'extérieur de la ligne à 45° , ce qui indique une modélisation réussie du processus. Cela suggère que le modèle RSM est capable de représenter de manière adéquate la relation entre les variables d'entrée et les indices de qualité de l'eau dans différentes saisons.



Figures VI.1. Graphique de probabilité normale en fonction des résidus pour (a) automne, (c) hiver, (e) printemps et (g) été.

Nous avons également évalué l'adéquation du modèle statistique en utilisant des graphiques, comme illustré dans les **figures VI.2. b, d, f, h**. Ces graphiques ont permis de comparer les valeurs observées aux valeurs prédites, conformément à la méthode établie par (Mohammed et al. 2023). Ils ont révélé un accord satisfaisant entre les données expérimentales réelles et les valeurs prédites par le modèle. Ces résultats confirment l'efficacité des modèles statistiques utilisés pour prédire les indices de qualité de l'eau pour les saisons d'automne, d'hiver, de printemps et d'été WQI_{AUT} , WQI_{WIN} , WQI_{SPR} , et WQI_{SUM} .



Figures VI.2. Courbes de variation saisonnière de WQI observé et prédit pour (b) automne, (d) hiver, (f) printemps et (h) été.

Sur la base des données expérimentales, les relations de surface de réponse entre les différentes variables ont été analysées et représentées dans les **Tableaux VI.3, VI.4, VI.5 et VI.6**. Ces tableaux présentent les interactions complexes entre les variables d'entrée, telles que le pH, la température, les phosphates et les hydrocarbures, et leur impact sur les indices de qualité de l'eau pour les différentes saisons. Ces relations de surface de réponse permettent une visualisation claire des tendances et des effets des variables sur la qualité de l'eau, ce qui est essentiel pour comprendre et optimiser le processus de traitement des eaux usées de la raffinerie.

Tableau VI.3. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'automne.

Série d'expériences	Variables d'entrée				Réponses	
	Automne				Automne	
	A-pH	B-T (°C)	C-PO ₄ (mg/l)	D-CxHy (mg/l)	WQI Exp	WQI RSM
1	7.6	29	1.5	0	36.56	37.69
2	7.7	29	0.8	0.1	25.94	26.47
3	7.5	30	0.4	0.7	28.53	29.06
4	7.5	29	1	0.3	21.98	22.23
5	7.6	31	0.9	0.1	27.66	26.47
6	7.4	28	0.8	0.1	25.62	25.01
7	7.5	26	1.5	0	28.11	26.22
8	7.6	26	0.8	0.1	23.71	26.47
9	7.7	26	0.8	0.1	22.88	26.09
10	7.6	31	1	0	40.66	38.23
11	7.6	23	0.3	0	13.85	13.8
12	7.4	23	0.2	0.1	24.91	25.75
13	7.6	25	0.1	0	28.34	26.47
14	7.5	28	2.2	0	23.12	21.08
15	7.7	26	0.5	0.1	20.93	21.39
16	7.6	29	0.6	0.3	26.85	27.14
17	7.2	26	0.8	0	26.79	27.93
18	7.5	29	0.8	0	27.24	27.84
19	7.7	28	1	0	19.73	21.76
20	7.4	28	0.5	0.1	17.84	17.83
21	7.7	26	0.8	0	26.71	26.47
22	7.5	23	0.4	0.1	25.62	25.91
23	7.5	27	0.8	0	23.63	23.33
24	7.5	26	1.1	0	21.23	21.41
25	7.8	27	0.5	0.2	21.5	22.53
26	7.8	27	1.3	0	22.25	21
27	7.8	28	1.1	0	21.82	20.53
28	7.5	27	1.8	0.1	27.46	25.91
29	7.2	27	0.2	0.1	22.53	22

Tableau VI.4. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'hiver.

Série d'expériences	Variables entrée				Réponses	
	Hiver				Hiver	
	A-pH	B-T (°C)	C-PO ₄ (mg/l)	D-CxHy (mg/l)	WQI Exp	WQI RSM
1	7.5	26	4.9	0.1	32.96	32.35
2	8	27	0.2	0	28.78	29.26
3	7.2	26	1.1	0.1	15.69	15.14
4	7.8	22	0.8	0	26.34	28.3
5	8.1	20	1.9	0	30.66	31.55
6	7.6	21	2.1	0.1	32.93	33.17
7	7.9	19	2.4	0.1	32.44	32.88
8	7.3	18	0.4	0.1	13.6	12.12
9	7.5	25	0.5	0.1	20.44	21.12
10	7.7	20	1.2	0	24.84	24.51
11	7.7	17	0.3	0.2	24.18	24.34
12	7.9	18	0.3	0	26.19	26.08
13	8	24	0.3	0	32.28	27.44
14	7.8	24	0.2	0	25.36	28.05
15	7.2	23	1	0	14.23	16.2
16	7.5	16	0.2	0	18.52	19.19
17	6.7	19	0.4	0.1	0.67	11.19
18	6.7	18	1.5	0	3.34	2.87
19	7.8	16	1.8	0	27.5	27.23
20	7.7	16	0	0.2	17.75	16.02
21	8	18	1.7	0	32.15	31.68
22	7.6	18	0.4	0.2	28.92	28.31
23	7.3	19	0.2	0.1	13.41	13.3
24	7.5	19	0.6	0.1	18.73	18.01
25	7.3	18	0.3	0	13.02	12.51
26	7.3	21	0.2	0	24.52	21.75
27	7.3	20	0.4	0.2	14.23	14.68
28	7.4	19	0.4	0.1	15.9	11.19
29	7.4	19	0.4	0.1	15.98	11.19

Tableau VI.5. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données de printemps.

Série d'expériences	Variables d'entrée				Réponses	
	Printemps				Printemps	
	A-pH	B-T (°C)	C-PO ₄ (mg/l)	D-CxHy (mg/l)	WQI Exp	WQI RSM
1	7.8	27	2	0	31.53	30.7
2	7.5	31	0.6	0	22.31	22.83
3	7.4	29	0.5	0	21.05	20.18
4	7.4	23	1.3	0	18.45	19.92
5	7.2	23	1.3	0.2	17.72	16.19
6	7.5	25	2	0	22.2	21.91
7	7.5	19	1.6	0.1	22.35	21.76
8	7.9	25	1.6	0	31.76	31.86
9	8.1	27	1.9	0.1	37.92	38
10	7.3	27	0.6	0.2	17.31	18.07
11	8	29	1.9	0	36.21	37.03
12	7.9	22	1	0.1	31.63	31.56
13	7.4	25	2.1	0.2	19.8	20.83
14	7.1	26	0.2	0	15.12	13.55
15	7.2	25	0.5	0.1	15.54	16.6
16	7.5	25	0.8	0.1	22.13	23.2
17	7.6	26	1.6	0.3	26.67	25.75
18	7.6	26	0.3	0.1	26.39	25.55
19	7	27	0.2	0.1	9.31	10.28
20	7.6	25	0.2	0	26.34	26.31
21	7.6	25	0.2	0	26.32	26.34
22	7.7	25	0.8	0.1	27.42	27.77
23	7.6	25	0.8	0.1	26.34	25.5
24	7.2	30	0.4	0.1	15.94	14.67
25	7.6	30	1.5	0.2	26.11	26.66
26	7.7	30	1.4	0	30.49	28.98
27	7.4	30	0.5	0	18.4	20.06
28	7.5	21	1.8	0.2	22.03	22.47
29	7.6	24	0.3	0.4	25.24	25.49

Tableau VI.6. Conception expérimentale de la méthode de surface de réponse (RSM) pour les données d'été.

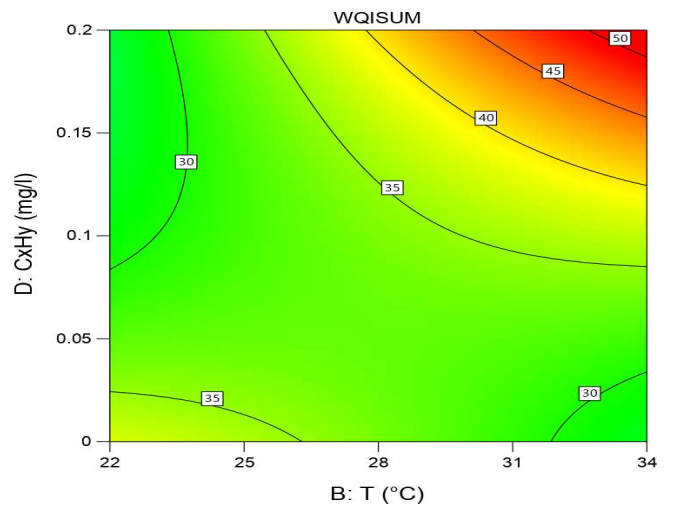

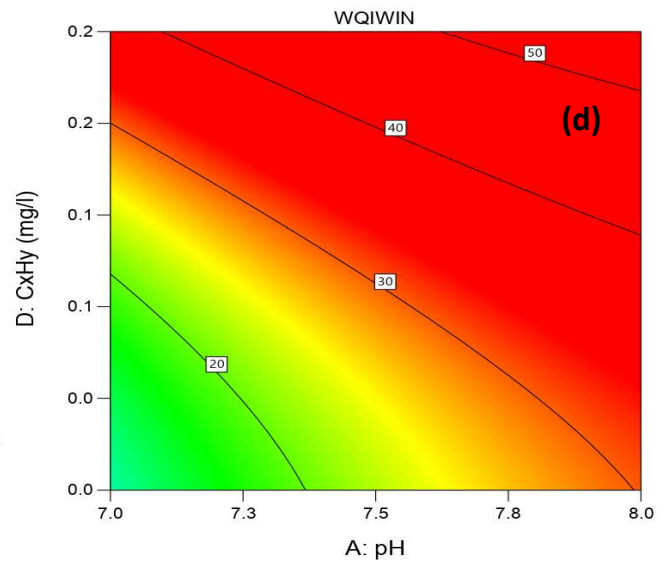

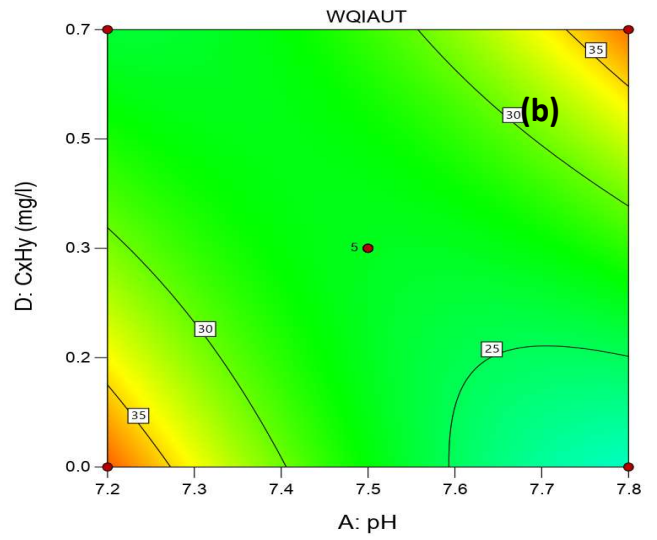
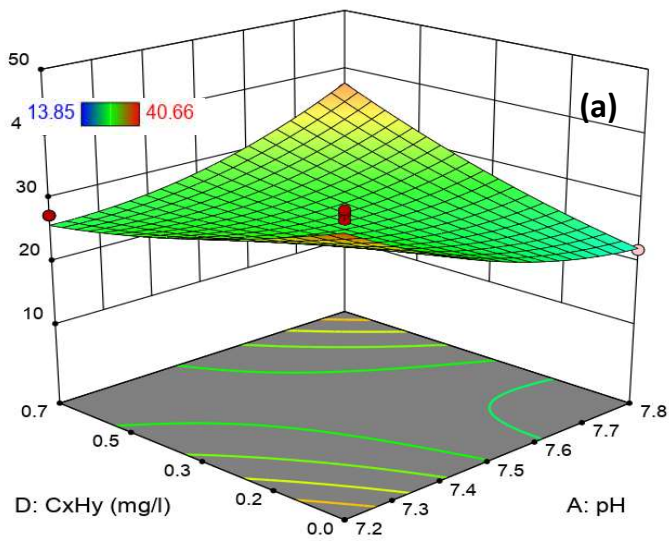
Série d'expériences	Variables d'entrée				Réponses	
	Eté				Eté	
	A-pH	B-T (°C)	C-PO ₄ (mg/l)	D-CxHy (mg/l)	WQI Exp	WQI RSM
1	7.4	23	0.3	0.2	16.41	15.79
2	7.5	24	0.2	0.1	22.25	21.27
3	7.3	29	0.3	0.1	12.65	15.56
4	8.6	22	0.8	0.1	44.26	42.84
5	8.3	23	0.8	0.1	37.92	37.26
6	7.4	23	1	0.1	12.36	12.68
7	7.4	27	0.7	0.1	16.57	15.6
8	7.5	27	1.5	0	22.42	21.88
9	7.8	29	0.3	0.1	27.64	26.55
10	8.5	30	1.4	0	49.34	47.88
11	8.4	25	0.8	0.1	35.36	40.58
12	7.5	26	0.9	0	21.43	21.09
13	8.7	29	1	0.1	49.13	48.71
14	7	23	0.5	0	8.57	8.95
15	7.5	32	0.5	0.1	22.46	20.82
16	8.1	28	0.9	0	35.1	35.25
17	8.2	29	0.8	0.1	37.52	37.51
18	8.3	30	0.8	0.1	40.15	40
19	8.2	34	1.4	0	37.66	37.89
20	8.2	34	1.4	0	37.12	37.89
21	8.2	34	1.4	0	37.66	37.89
22	8.2	34	1.4	0	37.66	37.89
23	8.4	28	0.7	0.1	41.32	40.96
24	8.5	28	0.8	0.1	43.9	43.6
25	8.5	30	0.8	0.1	44.36	43.95
26	8.3	28	0.5	0	40.58	39.89
27	8.2	27	0.5	0.1	37.37	37.21
28	8.2	27	0.5	0	37.14	38.61
29	7.5	22	1.8	0	22.57	22.88

Nous pouvons également visualiser graphiquement la relation entre les courbes de surface de réponse tridimensionnelles de chaque variable et les lignes de contour utilisées pour évaluer le niveau expérimental, le type d'interaction entre les deux variables et les deux facteurs. La forme du tracé (circulaire ou elliptique) permet de déterminer si l'interaction entre les paramètres est significative ou non.

La Figure VI.3 présente les graphiques de surface de réponse des trois variables étudiées : AC, BC et CE. Ces graphiques ont révélé des relations binaires significatives pour les quatre saisons (p -value < 0.005). Les autres relations binaires n'ont pas été spécifiquement étudiées car elles n'étaient pas aussi pertinentes pour la recherche.

Cette représentation graphique illustre l'impact du pH et de CxHy sur l'indice de qualité de l'eau WQI pour WQI_{AUT} , WQI_{WIN} dans des conditions stables de $T = 28^{\circ}\text{C}$, $\text{PO}_4^{-3} = 1 \text{ mg/l}$ et $T = 27^{\circ}\text{C}$, $\text{PO}_4 = 1.2 \text{ mg/l}$ respectivement. Les résultats ont montré qu'une augmentation du pH et de CxHy entraînait une amélioration de l'indice de qualité de l'eau WQI. En se basant sur la valeur du terme AD, il est possible de conclure que la relation entre le pH et CxHy est significative en hiver et en automne (P -value < 0.0001). De plus, selon le terme BD, il a été observé que WQI_{SUM} augmente en été avec l'augmentation de la température et de CxHy, tout en maintenant une concentration de PO_4^{-3} de 1 mg/l constante et un pH de 5 constant.

En outre, il a été constaté que WQI est plus sensible aux variations du pH quelles que soit la saison.



Figures VI.3. Diagrammes 3D et 2D de surface de réponse pour (a–b) WQI_{AUT} (pH-CxHy), (c–d) WQI_{WIN} (pH-CxHy) and (c-d) WQI_{SUM} (T-CxHy).

3.2. Optimisation des réponses numériques

Dans le cadre de l'optimisation des réponses numériques, quatre variables ont été prises en compte : le pH, la température, la teneur en phosphate et la teneur totale en hydrocarbures. Ces variables ont été déterminées à l'aide de la méthode RSM afin d'optimiser quatre réponses différentes. Le processus d'optimisation RSM a été réalisé à l'aide du logiciel Design Expert en utilisant la fonction de désirabilité. Chaque facteur, qu'il soit indépendant ou dépendant, possède une plage de valeurs significative. Pour obtenir des résultats optimaux respectant à la fois les limites inférieures et supérieures, une stratégie d'optimisation multi-objectif (Cao et al. 2018) a été adoptée.

La désirabilité détermine dans quelle mesure une solution répond aux objectifs fixés, et il est recommandé d'atteindre un niveau de désirabilité proche de 1 pour obtenir des résultats optimaux. Le **tableau VI.5** présente les valeurs idéales de pH, de température, de phosphate et d'hydrocarbures pour les quatre réponses, à savoir WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} . Il a été démontré que les réponses peuvent être optimisées lorsque la valeur de désirabilité atteint 1. Pour WQI_{AUT} , WQI_{WIN} , WQI_{SPR} , and WQI_{SUM} , les quatre valeurs de réponse idéales sont 9,77, 1,36, 9,14 et 5,76.

Ces valeurs sont de 7,18, 6,75, 7,00, 7,27 pour le pH, 34,79, 17,14, 30,26, et 33,22 pour la température, 2,25, 0,36, 0,72, et 0,28 mg/l pour les phosphates, et 0,30, 0,08, 0,04, et 0,04 mg/l pour les hydrocarbures.

Ces valeurs optimales garantissent des performances maximales du système d'épuration, contribuant ainsi à l'amélioration globale de la qualité de l'eau traitée.

Tableau VI.7. Les réponses optimisées des paramètres physico-chimiques via une approche numérique.

Saison	pH	T (°C)	PO ₄ ³⁻ (mg/l)	C _x H _y (mg/l)	WQI.
Automne	7.18	34.79	2.25	0.30	9.77
Hiver	6.75	17.14	0.36	0.08	1.36
Printemps	7.00	30.26	0.72	0.04	9.14
Eté	7.27	33.22	0.28	0.04	5.76

4. Conclusion

Dans ce chapitre, les modèles générés à l'aide de la méthodologie de la Réponse de Surface ont démontré une capacité prometteuse à prédire l'indice de qualité de l'eau (WQI). Ces modèles ont montré aussi une fiabilité statistiquement significative avec une valeur de p inférieure à 0,05, confirmant ainsi leur robustesse au niveau de confiance de 95 %. Les conclusions tirées de cette analyse mettent en lumière l'efficacité remarquable et durable du procédé d'épuration des eaux usées au niveau de la STEP de la raffinerie de Skikda.

Chapitre VII : Application des réseaux de neurones artificiels à la prévision de l'indice de qualité de l'eau

1.Introduction

Dans ce chapitre, nous introduisons les résultats de notre recherche qui se concentre sur l'évaluation de l'efficacité des réseaux de neurones artificiels dans la prédiction de l'indice de qualité de l'eau. En analysant de manière approfondie les performances obtenues, notre objectif est de mettre en évidence l'impact significatif de ces techniques sur la fiabilité des prévisions pour la surveillance de la qualité de l'eau, dans le but de protéger l'environnement et la santé humaine.

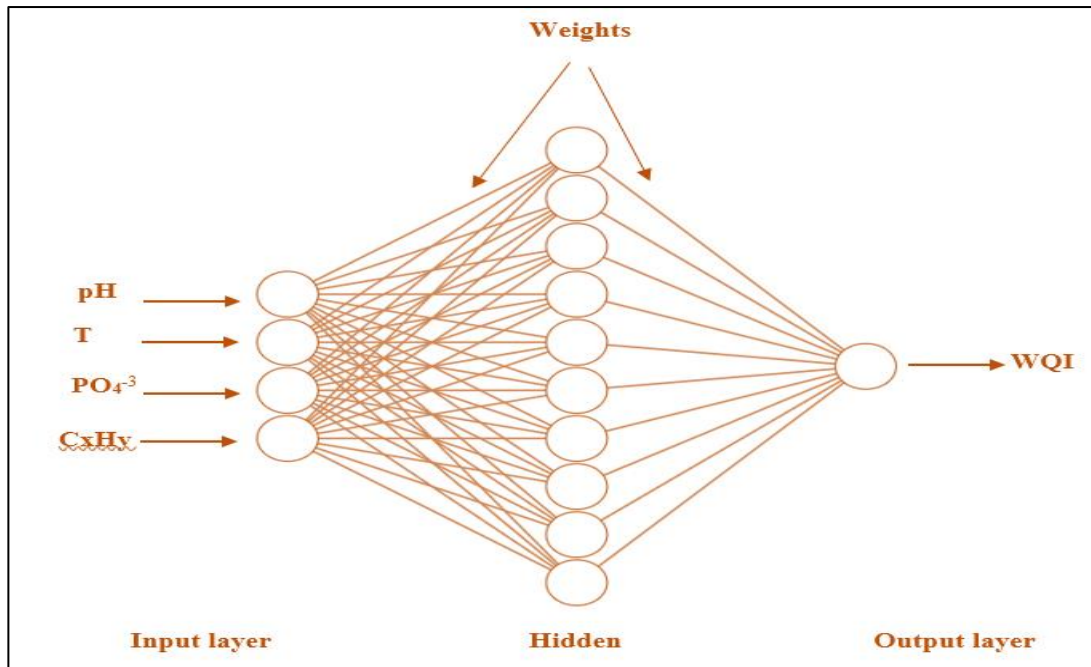
2. Matériel et méthodes

2.1. Processus de modélisation par ANN

Le processus de modélisation de la qualité des eaux usées de la station d'épuration de la raffinerie a été élaboré en utilisant un réseau de neurones artificiels (ANN) mis en place avec MATLAB version R2019a. Cet outil a évalué la relation entre les variables d'entrée et de sortie, créant ainsi une équation de régression de prédictibilité basée sur les données collectées. Pour former l'ANN, un perceptron multicouche (MLP) a été utilisé, comprenant des couches d'entrée, de sortie et cachées, qui sont connectées en ajustant les poids et les écarts (Cao et al. 2018) (**Figure VII.1**).

Les corrélations non linéaires entre les entrées et les sorties ont pu être mesurées grâce à l'algorithme d'apprentissage. L'algorithme de rétropropagation Levenberg-Marquardt (LM) a été choisi dans cette étude en raison de son efficacité dans les réseaux de rétroaction, où les données expérimentales sont divisées en trois parties : 70 % pour l'apprentissage, 15 % pour la validation et 15% pour le test (Khosravi et al. 2023).

La phase de validation est essentielle à l'évaluation de la fiabilité du modèle. Elle est également utilisée pour ajuster les paramètres et éviter le surapprentissage. Sa performance démontre la capacité du modèle à s'adapter à de nouvelles données. Ensuite, le modèle est évalué sur un ensemble de tests différent qui n'a pas été utilisé lors de l'apprentissage et de la validation, ce qui permet une évaluation indépendante de ses performances sur de nouvelles données. Le réseau neuronal comprend 4 noeuds (pH, T, PO_4^{-3} et CxHy) dans la couche d'entrée, tandis que la couche de sortie comporte 1 nœud (WQI). Le code de moyenne pondérée calcule automatiquement le nombre de neurones de la couche cachée.



Figures VII.1. Architecture du réseau de neurone artificiel

3. Résultats et discussions

L'algorithme de Levenberg-Marquardt (TRAINLM) a été choisi pour l'architecture ANN utilisée pour simuler l'indice de qualité de l'eau de la STEP de la raffinerie de Skikda au pas de temps saisonnier WQI_{AUT} , WQI_{WIN} , WQI_{SPR} , and WQI_{SUM} avec sa fonction de transfert (TANSIG) comme résultat, qui sont respectivement (4-10-1), (4-8-1), (4-7-1) et (4-8-1). Le **tableau VII.1** montre clairement les performances des modèles ANN pendant l'apprentissage, validation et test, y compris de faibles valeurs de MSE et un coefficient de détermination R^2 élevé.

Les faibles valeurs de MSE et les coefficients de détermination R^2 montrent que les performances des modèles ANN dans toutes les phases (apprentissage, validation et test) sont très encourageantes. Ces résultats indiquent que les modèles ANN ont pu généraliser et prédire avec précision l'indice de qualité de l'eau à pas de temps saisonnier.

L'utilisation de l'algorithme de Levenberg-Marquardt (TRAINLM) a montré son efficacité dans l'apprentissage des modèles ANN pour simuler l'indice de qualité de l'eau, ce qui a conduit à des performances robustes pendant la phase de test.

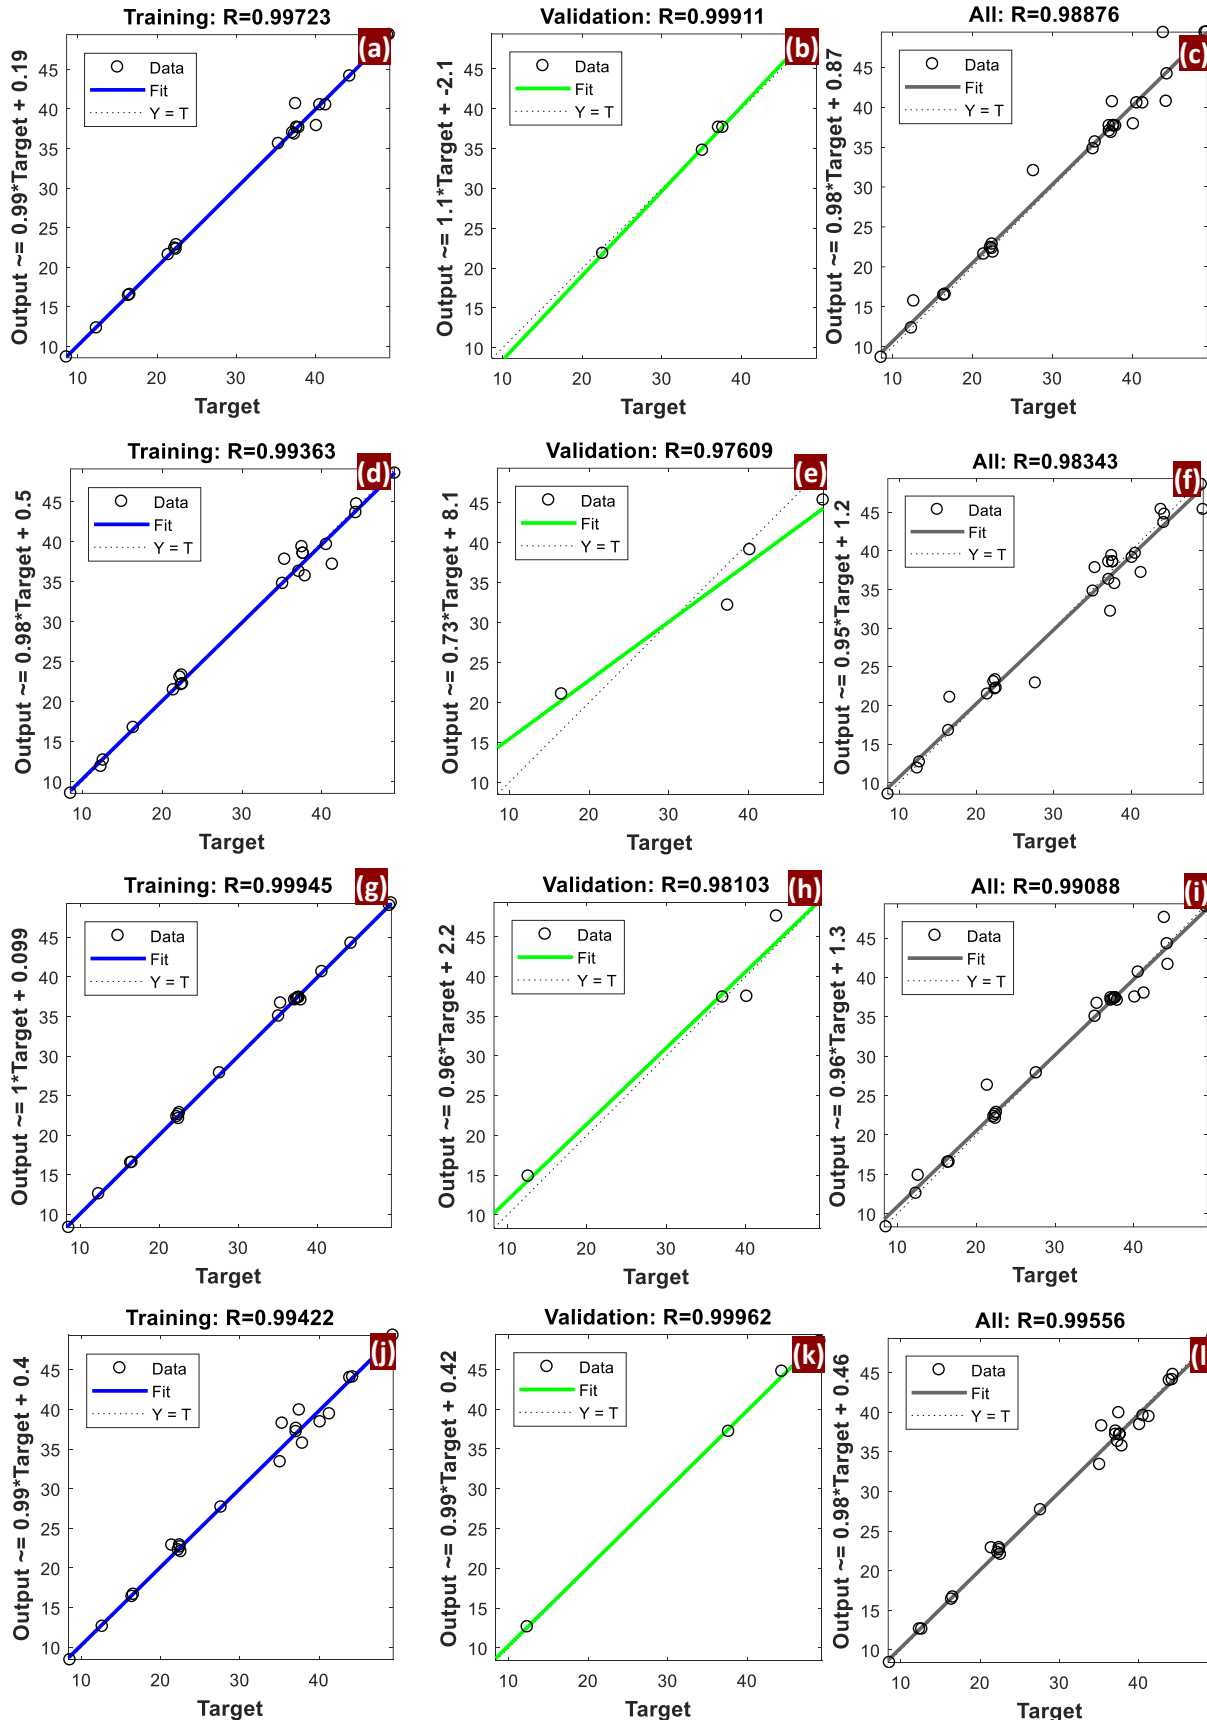
La fonction de transfert TANSIG utilisée dans les couches cachées des réseaux de neurones a également contribué à améliorer les performances des modèles ANN en signalant les relations non linéaires entre les variables d'entrée et de sortie.

Ces résultats montrent la capacité des modèles ANN à être utilisés efficacement dans la modélisation de la qualité de l'eau dans les stations d'épuration, offrant ainsi un outil précieux pour la surveillance et la gestion de la qualité de l'eau dans les installations industrielles.

Tableau VII.1. Performances des modèles ANN lors de l'apprentissage, validation et de test.

Modèles	Architecture	%	Données	MSE	R-value	
<i>WQI_{AUT}</i>	4 10 1	Apprentissage	70	21	1.02523E-01	0.9972
		Validation	15	4	2.48341E-01	0.9991
		Test	15	4	1.20454E-01	0.9637
<i>WQI_{WIN}</i>	4 8 1	Apprentissage	70	21	2.99323E-02	0.9942
		Validation	15	4	1.12320E-02	0.9996
		Test	15	4	7.14229E-01	0.9780
<i>WQI_{SPR}</i>	4 7 1	Apprentissage	70	21	1.55737E-01	0.9945
		Validation	15	4	1.24018E-01	0.9810
		Test	15	4	2.53777E-01	0.9925
<i>WQI_{SUM}</i>	4 8 1	Apprentissage	70	21	2.88215E-02	0.9936
		Validation	15	4	2.25298E-01	0.9761
		Test	15	4	5.37117E-01	0.9907


Les données d'entrée et de sortie (comme illustré dans **la Figure VII.2**) ont été soigneusement sélectionnées pour obtenir les meilleures valeurs de R^2 dans la couche cachée, tout en minimisant la valeur de MSE, dans le but d'améliorer les capacités de prédiction (Jana et al. 2022). Les coefficients de détermination R^2 obtenus sont respectivement de 0,9887, 0,9834, 0,9909 et 0,9956 pour WQI_{AUT} , WQI_{WIN} , WQI_{SPR} , et WQI_{SUM} , tandis que les RMSE sont d'environ 0,23385, 4,3472, 6,4143 et 0,2066, respectivement. Ces résultats confirment les conclusions antérieures de (Mohammed et al., 2023 ; Sibiya et al., 2022) concernant l'efficacité des ANN dans la modélisation et la prédiction de la qualité de l'eau.



Figures VII.2. Valeurs réelles de WQI comparées avec les valeurs prédites par le modèle ANN pour l'apprentissage, validation et test (a-c) WQI_{AUT} , (d-f) WQI_{WIN} , (g-i) WQI_{SPR} et (j-l) WQI_{SUM} .

Dans l'analyse des performances, l'évaluation du taux d'erreur entre les résultats des tests et les projections de l'ANN est une étape importante. Comme illustré dans **La figure V.3**, elle montre que cette évaluation révèle une erreur remarquablement faible, concentrée autour de la zone zéro d'erreur et de ses alentours. Cette constatation souligne la précision des prévisions des modèles ANN.

Comme le montrent les travaux de Sibiya et al. (2022), la faible valeur du taux d'erreur observée au cours de la phase d'apprentissage ou training confirme le succès du processus dans son ensemble. La capacité du modèle à détecter efficacement les relations complexes entre les variables d'entrée et à produire des résultats fiables et précis est démontrée par cette faible erreur. Par conséquent, cette étape de validation confirme la fiabilité et la robustesse de l'ANN dans sa capacité à généraliser et à prédire avec précision des relations non linéaires.



Figures VII.3. Histogramme d'erreur pour (a) WQI_{AUT} , (b) WQI_{WIN} , (c) WQI_{SPR} and (d) WQI_{SUM} .

L'utilisation des équations présentées dans le **tableau VII.2** pour développer les modèles ANN destinés à prédire les quatre WQI, à savoir WQI_{AUT} , WQI_{WIN} , WQI_{SPR} , et WQI_{SUM} . Ces modèles ont démontré une capacité satisfaisante à prédire les niveaux de qualité de l'eau, cela représente une progression importante dans ce domaine de recherche.

Les résultats des modèles ANN confirment de manière significative les conclusions précédemment établies par plusieurs travaux de recherche, notamment ceux de Azrou et al. (2022), Kouadri et al. (2021) et Nayak et al. (2021). Ces résultats antérieurs ont révélé de nombreux aspects de la qualité de l'eau et ont aidé à comprendre les facteurs qui l'affectent.

Tableau VII.2. Modèles mathématiques de WQI des rejets de la STEP de la raffinerie RA1K pour les quatre saisons (Mellal et al. 2024).

Réponses	Modèles mathématiques
ANN	$-2.9977 \times H_1 + 27.9539 \times H_2 + 89.4022 \times H_3 - 107.3826 \times H_4 - 27.0672 \times H_5 + 2.5957 \times H_6 + 23.8392 \times H_7 - 27.1758 \times H_8 + 22.7454$
WQI_{SUM}	$\begin{cases} H_1 = \tanh(0.5 \times (-0.2187 \times PH + 0.1925 \times T + 0.8246 \times PO4 - 4.4677 \times CxHy - 3.6529)) \\ H_2 = \tanh(0.5 \times (-1.1281 \times PH + 0.5616 \times T - 1.6752 \times PO4 + 3.5864 \times CxHy - 5.2382)) \\ H_3 = \tanh(0.5 \times (-0.6330 \times PH + 0.1744 \times T - 1.3725 \times PO4 - 12.7845 \times CxHy + 2.8267)) \\ H_4 = \tanh(0.5 \times (-0.7505 \times PH + 0.2274 \times T - 1.5682 \times PO4 - 12.1623 \times CxHy + 2.2360)) \\ H_5 = \tanh(0.5 \times (-1.8955 \times PH - 0.0740 \times T + 2.4103 \times PO4 - 13.5591 \times CxHy + 15.047)) \\ H_6 = \tanh(0.5 \times (-0.1681 \times PH - 0.2075 \times T + 0.2545 \times PO4 - 7.8557 \times CxHy + 6.4663)) \\ H_7 = \tanh(0.5 \times (0.0262 \times PH + 0.0214 \times T - 0.5770 \times PO4 - 16.7944 \times CxHy - 0.4504)) \\ H_8 = \tanh(0.5 \times (-0.0306 \times PH + 0.1908 \times T - 3.0121 \times PO4 + 10.4693 \times CxHy - 4.1376)) \end{cases}$
WQI_{SPR}	$5.6743 \times H_1 - 2.5278 \times H_2 + 9.9360 \times H_3 + 9.6558 \times H_4 - 8.9086 \times H_5 - 5.6055 \times H_6 + 9.6168 \times H_7 + 19.9473$ $\begin{cases} H_1 = \tanh(0.5 \times (-8.1586 \times PH - 23.3778 \times T + 2.4820 \times PO4 + 17.3178 \times CxHy - 14.3265)) \\ H_2 = \tanh(0.5 \times (1.1392 \times PH - 17.2122 \times T - 0.6716 \times PO4 - 4.1567 \times CxHy - 64.4085)) \\ H_3 = \tanh(0.5 \times (-0.0360 \times PH + 0.8424 \times T - 0.3383 \times PO4 - 3.4592 \times CxHy + 2.8943)) \\ H_4 = \tanh(0.5 \times (2.0849 \times PH + 3.5697 \times T - 0.4601 \times PO4 + 0.9225 \times CxHy - 4.4633)) \\ H_5 = \tanh(0.5 \times (0.9499 \times PH + 19.0329 \times T - 1.8085 \times PO4 + 35.5022 \times CxHy + 52.1556)) \\ H_6 = \tanh(0.5 \times (-3.9446 \times PH + 17.3732 \times T - 0.5295 \times PO4 - 8.9011 \times CxHy + 87.0562)) \\ H_7 = \tanh(0.5 \times (0.6519 \times PH + 22.6904 \times T - 1.1039 \times PO4 + 10.0689 \times CxHy + 71.4788)) \end{cases}$

$$-17.5118 \times H_1 - 2.1258 \times H_2 - 0.1690 \times H_3 - 1.4884 \times H_4 + 3.5114 \times H_5 - 4.2983 \times H_6 \\ - 4.9085 \times H_7 + 11.3925 \times H_8 + 24.1618$$

$$WQI_{WIN} \left\{ \begin{array}{l} H_1 = \tanh(0.5 \times (-1.4425 \times CxHy + 1.4932 \times PO4 - 1.9892 \times T - 0.7819 \times PH + 30.9690)) \\ H_2 = \tanh(0.5 \times (-33.1950 \times CxHy + 2.3401 \times PO4 - 6.6179 \times T + 1.8276 \times PH + 62.2781)) \\ H_3 = \tanh(0.5 \times (-0.4386 \times CxHy - 0.7222 \times PO4 - 3.0205 \times T - 3.1786 \times PH + 46.1216)) \\ H_4 = \tanh(0.5 \times (11.6091 \times CxHy - 1.4401 \times PO4 - 1.9917 \times T - 4.7438 \times PH + 43.9896)) \\ H_5 = \tanh(0.5 \times (12.6138 \times CxHy + 2.6782 \times PO4 - 2.4831 \times T + 0.8933 \times PH + 28.9087)) \\ H_6 = \tanh(0.5 \times (77.4605 \times CxHy - 2.2662 \times PO4 + 12.094 \times T + 0.4464 \times PH - 130.549)) \\ H_7 = \tanh(0.5 \times (45.2139 \times CxHy + 0.5344 \times PO4 - 1.5756 \times T - 3.4272 \times PH + 44.0099)) \\ H_8 = \tanh(0.5 \times (43.0421 \times CxHy + 8.7289 \times PO4 - 5.5669 \times T + 4.8732 \times PH + 51.0105)) \end{array} \right.$$

$$4.1649 \times H_1 + 1.17903 \times H_2 - 42.3170 \times H_3 - 52.6197 \times H_4 - 8.7982 \times H_5 + 28.3802 \times H_6 \\ - 35.3530 \times H_7 - 1.1006 \times H_8 - 13.9887 \times H_9 + 8.2380 \times H_{10} - 2.8607$$


$$WQI_{AUT} \left\{ \begin{array}{l} H_1 = \tanh(0.5 \times (6.5016 \times CxHy + 2.7154 \times PO4 + 0.0916 \times T - 5.5625 \times PH + 21.820)) \\ H_2 = \tanh(0.5 \times (6.9416 \times CxHy + 0.3634 \times PO4 + 12.291 \times T - 1.4241 \times PH + 35.7653)) \\ H_3 = \tanh(0.5 \times (4.5840 \times CxHy + 3.0938 \times PO4 - 0.7287 \times T - 0.1005 \times PH - 25.2189)) \\ H_4 = \tanh(0.5 \times (-3.3103 \times CxHy - 6.3223 \times PO4 - 0.0044 \times T - 1.8718 \times PH + 60.5308)) \\ H_5 = \tanh(0.5 \times (0.8063 \times CxHy + 7.3179 \times PO4 + 5.7287 \times T + 2.5532 \times PH - 59.2878)) \\ H_6 = \tanh(0.5 \times (5.4001 \times CxHy + 0.2433 \times PO4 + 6.5774 \times T + 1.4245 \times PH + 1.3871)) \\ H_7 = \tanh(0.5 \times (1.6037 \times CxHy + 7.6616 \times PO4 - 4.9686 \times T + 2.4887 \times PH - 85.6522)) \\ H_8 = \tanh(0.5 \times (4.5486 \times CxHy + 3.8707 \times PO4 + 0.8689 \times T + 1.8350 \times PH - 40.1982)) \\ H_9 = \tanh(0.5 \times (14.8157 \times CxHy - 3.4284 \times PO4 + 13.832 \times T + 1.3383 \times PH + 42.5133)) \\ H_{10} = \tanh(0.5 \times (0.0640 \times CxHy - 1.9433 \times PO4 + 2.5045 \times T - 0.3902 \times PH + 21.1156)) \end{array} \right.$$

4. Comparaison des modèles ANN et RSM

La comparaison des modèles ANN et RSM dans la représentation de WQI provenant de la STEP de la raffinerie a été une étape cruciale pour évaluer l'aptitude de ces modèles à prédire la complexité et la non-linéarité des données. La nature non linéaire de WQI nécessitait des techniques statistiques complexes pour sa modélisation.

La Figure VII.4 présente une comparaison visuelle entre les valeurs prédites par les modèles ANN et RSM, ainsi que les données expérimentales réelles. Les graphiques montrent un excellent accord entre les résultats des modèles et les données expérimentales pour tous WQI des quatre saisons : WQI_{AUT}, WQI_{WIN}, WQI_{SPR}, et WQI_{SUM}. Cette observation suggère que les deux modèles sont capables de représenter de manière satisfaisante la relation entre les variables d'entrée et les WQI, malgré la complexité et la non-linéarité des données.

On peut confirmer que l'approche basée sur les ANN et celle basée sur la méthode de réponse de surface sont toutes deux efficaces pour modéliser WQI. Cependant, il convient de noter que chaque modèle présente des bénéfices et des désavantages. Par exemple, les modèles RSM permettent une interprétation et une compréhension plus directes des effets des variables d'entrée sur la sortie, tandis que les modèles ANN prédit mieux les relations complexes et non linéaires entre les variables.



Figures VII.4. Comparaison des valeurs réelles et prédites à l'aide des modèles ANN et RSM pour : (a) WQI_{AUT} , (b) WQI_{WIN} , (c) WQI_{SPR} and (d) WQI_{SUM} .

5. Performances des modèles

Pour démontrer les performances des modèles ANN et RSM, des mesures statistiques telles que R^2 , RMSE, MSE et MAPE ont été utilisés pour analyser la corrélation entre les résultats réels et prédits révélés dans le **tableau VII.3**.

Le **tableau IV.3** présente les performances des modèles utilisés pour la prévision des indices de qualité de l'eau, comparant les résultats des modèles RSM et ANN pour les indices à pas de temps saisonnier, à savoir WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} . Les performances sont estimées à l'aide de quatre grandeurs statistiques, notamment le R^2 , RMSE, MSE et le MAPE.

Pour tous les WQI, les modèles ANN ont des valeurs de R^2 beaucoup plus élevées que les modèles RSM. Cela indique que les modèles ANN sont plus responsables de la variance des données que les modèles RSM. En d'autres termes, les modèles ANN s'ajustent mieux aux données et offrent une meilleure capacité de prédiction.

Pour tous les WQI, les modèles ANN présentent des valeurs de RMSE et MSE considérablement plus faibles que les modèles RSM. Cela signifie que par rapport aux données réelles, les prédictions des modèles ANN sont plus précises et moins sujettes à l'erreur que les prédictions des modèles RSM.

Les modèles ANN montrent également des valeurs de MAPE plus faibles que les modèles RSM, ce qui indique une plus grande précision des prédictions des modèles ANN en termes de pourcentage d'erreur moyen.

Les deux modèles montrent que les résultats expérimentaux coïncident avec les résultats prédits. Pour les modèles RSM, les valeurs de R^2 sont de 0,9279, 0,9378, 0,9802 et 0,98866, tandis que les modèles ANN pour les valeurs WQI_{AUT} , WQI_{WIN} , WQI_{SPR} et WQI_{SUM} sont presque identiques à 1. Il a été démontré que les prévisions des modèles ANNs sont meilleures par rapport aux modèles statistiques RSM-BBD.

Les modèles ANNs offrent une précision beaucoup plus élevée que les modèles RSM en raison de leurs valeurs RMSE, MSE et MAPE inférieures et de leur coefficient de détermination plus élevé. Bien que l'ANN et le RSM puissent prédire le processus, ANN a été le plus précis (Mohammed et al., 2023). Le résultat est expliqué par la capacité d'ANN à gérer tout type de non-linéarité, alors

que le modèle RSM est basé sur une relation quadratique irrégulière (Khayet, Cojocar, and Essalhi 2011)

Tableau VII.3. Performances des modèles utilisés pour la prévision des WQI à pas de temps saisonnier (Mellal et al. 2024)

	WQI _{AUT}		WQI _{WIN}		WQI _{SPR}		WQI _{SUM}	
	RSM	ANN	RSM	ANN	RSM	ANN	RSM	ANN
R²	0.9279	0.9888	0.9378	0.9834	0.9802	0.9909	0.9866	0.9956
RMSE	0.147	0.0154	0.1266	0.0314	0.0192	0.0057	0.0965	0.0256
MSE	0.6325	0.1025	0.4209	0.0029	0.2401	0.0065	0.1236	0.0941
MAPE	0.1564	0.0266	0.0957	0.0115	0.112	0.0128	0.0291	0.0172

6. Conclusion

Les conclusions exposées dans ce chapitre indiquent que les modèles ANN dépassent les modèles RSM en termes de performances de prédiction pour tous les WQI étudiés. Les modèles ANN présentent des coefficients de détermination plus élevés et des erreurs moyennes plus faibles, Cela met en évidence leur aptitude accrue à prédire les relations complexes et non linéaires entre les variables d'entrée et à prédire avec précision les WQI. On peut dire que les modèles ANN peuvent être privilégiés pour la modélisation et la prédiction des WQI par rapport aux modèles RSM, en raison de leur capacité à offrir des prédictions plus précises et fiables.

Conclusion générale

Conclusion générale

Dans le cadre de cette étude sur la modélisation de WQI, un paramètre crucial pour la gestion durable de l'environnement, nous avons adopté une approche exploratoire et comparative en utilisant des modèles basés sur l'IA, notamment les ANN et la méthode de surface de réponse (RSM). Pour les ANN, nous avons choisi d'utiliser des perceptrons multicouches (MLPNN), tandis que pour la RSM, nous avons opté pour le modèle de plan expérimental Box-Behnken (BBD), qui s'est révélé bien adapté à notre objectif de recherche.

Le premier objectif de notre étude est d'évaluer et de prédire la qualité des rejets traités par la station d'épuration des eaux usées (STEP) du complexe de raffinage de pétrole de Skikda (RA1/k) et d'assurer l'évacuation d'une eau sans risque pour l'environnement.

L'évaluation du WQI a été effectuée à l'échelle saisonnière (automne, hiver, printemps et été), prenant en compte six paramètres de qualité de l'eau influençant le WQI : le pH, la température (T), la conductivité électrique (CE), le phosphate (PO_4), la demande chimique en oxygène (DCO) et les hydrocarbures totaux (CxHy). Les indices de performance tels que le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE), l'erreur quadratique moyenne (MSE) et le pourcentage d'erreur absolue moyenne (MAPE) ont été utilisés pour évaluer la pertinence des performances de tous les modèles.

Pour sélectionner les paramètres d'entrée les plus pertinents pour les modèles saisonniers évaluant le WQI, nous avons appliqué deux techniques qui sont l'analyse en composantes principales (ACP) et le test Gamma (GT). Ces méthodes ont permis de réduire la complexité des données et d'identifier les variables les plus significatives. Parmi celles-ci, seules quatre ont été retenues en raison de leur corrélation notable avec le WQI : le pH, la température, le phosphore et les hydrocarbures totaux. Cette sélection rigoureuse garantit que seules les variables les plus influentes sont prises en compte dans nos modèles, ce qui améliore leur précision et leur fiabilité dans la prévision de WQI.

L'examen détaillé des paramètres physico-chimiques des rejets traités au niveau de la STEP révèle des résultats très encourageants. En effet, ces données démontrent que les effluents traités sont en conformité avec les normes établies par JORA (2006), définissant les valeurs limites de rejets d'effluents liquides industriels où indiquant que ces rejets peuvent être déversés en toute sécurité dans l'Oued Marhoum, sans compromettre la qualité de l'eau ni porter atteinte à l'environnement, soulignant ainsi la fiabilité et l'efficacité du procédé d'épuration en

question. Ce procédé, conçu pour traiter les effluents industriels complexes, semble remplir son rôle de manière satisfaisante en éliminant efficacement les polluants et en améliorant la qualité de l'eau avant leur rejet dans le milieu naturel, ce qui confirme l'engagement de la raffinerie de Skikda en matière de protection de l'environnement et de gestion responsable des déchets industriels.

Les résultats des deux modèles montrent que les résultats expérimentaux et prédits correspondent étroitement dont les modèles générés à l'aide de l'ANN et de RSM ont présenté une bonne prédiction de l'indice de qualité de l'eau et étaient statistiquement significatifs ($p < 0,05$) au niveau de confiance de 95 %. Les valeurs R^2 pour les modèles ANN pour les modèles WQIAUT, WQIWIN, WQISPR et WQISUM sont presque identiques à 1, tandis que les valeurs des modèles RSM sont de 0,9279, 0,9378, 0,9802 et 0,98866. Il a été démontré que l'approche ANN s'est avérée meilleure en termes de prévision par rapport au modèle RSM-BBD, offrant ainsi une méthodologie plus efficace pour évaluer la qualité de l'eau rejetée.

Les variations saisonnières ont montré que le pH et la concentration en hydrocarbures exercent une influence significative sur la qualité de l'eau.

Les résultats de la comparaison entre les modèles ANN et RSM et les données expérimentales mettent en évidence leur capacité à représenter de manière fiable la nature non linéaire de l'indice de qualité de l'eau issu de la STEP de la raffinerie. Ces modèles offrent donc une approche efficace pour évaluer et prédire la qualité de l'eau, ce qui peut contribuer à une meilleure gestion des ressources hydriques et à la protection de l'environnement.

Les résultats devraient encourager les organisations et les autorités responsables de la gestion de la qualité de l'eau à reconnaître l'utilité des méthodes d'intelligence artificielle et à encourager l'adoption de modèles permettant de prédire avec précision la qualité de l'eau. L'approche ANN-RSM a été adaptée et appliquée dans le domaine du traitement des eaux usées pour apporter des solutions aux différents problèmes environnementaux.

Cependant, malgré les performances prometteuses des modèles ANN, il est important de noter que leur précision dépend de la qualité et de la quantité des données d'entrée disponibles. Des études futures pourraient explorer des séries de données plus vastes et diversifiées pour améliorer encore la capacité des modèles à prédire l'indice de qualité de l'eau avec une précision accrue. De plus, d'autres algorithmes d'apprentissage automatique pourraient être testés pour comparer et optimiser les performances des modèles.

Ces résultats ouvrent la voie aux futures applications pratiques, notamment dans le domaine de la gestion de l'eau et de la surveillance environnementale, où une évaluation précise de la qualité de l'eau est essentielle. En outre, ils soulignent l'importance croissante des techniques d'apprentissage automatique, telles que les réseaux de neurones artificiels, dans la modélisation et la prédiction de phénomènes complexes tels que la qualité de l'eau.

Ces résultats peuvent éclairer les discussions sur les orientations futures de la recherche sur la gestion de la qualité de l'eau, recommander la modélisation pour la prévision de la qualité de l'eau, reconnaître les avantages des techniques statistiques et d'intelligence artificielle et fournir une base pour les recherches futures. La pertinence des modèles développés dans le cadre de cette étude sera mise à l'essai pour les prévisions étendues au fur et à mesure que d'autres données seront disponibles.

Références bibliographiques

- Aazami, J., Esmaili-Sari, A., Abdoli, A., Sohrabi, H., & Van Den Brink, P. J. (2015). Monitoring and assessment of water health quality in the Tajan River, Iran using physicochemical, fish and macroinvertebrates indices. *Journal of Environmental Health Science and Engineering*, 13(1). <https://doi.org/10.1186/s40201-015-0186-y>
- Abai, E. A., Ombolo, A., Ngassoum, M. B., & Mbawala, A. (2014). Suivi de la qualité physico-chimique et bactériologique des eaux des cours d'eau de Ngaoundéré, au Cameroun. *Afrique Science : Revue Internationale Des Sciences et Technologie*, 10(4), 135–145. <https://doi.org/1813-548X>
- Abba, S. I., Abdulkadir, R. A., Sammen, S. S., Pham, B., Lawan, A. A., Esmaili, P., Malik, A., & Al-Ansari, N. (2021). Integrating feature extraction approaches with hybrid emotional neural networks for water quality index modeling. <https://doi.org/10.5195/9.7889>
- Abbas Merghem, K., El Halouani, H., Ali Alnedhary, A., Dssouli, K., Gharibi, E., Qaid Alansi, R., & al-Nahmi, F. (2016). Etude de l'impact des rejets d'eaux usées brutes et épurées sur la qualité de l'Oued Bani Houat (Bassin de Sanaa): Etude spatio-temporelle (Impact of raw and treated wastewater on quality surface water of Wadi Bani Houat (Sanaa Basin) Study spatial-temporal). *J. Mater. Environ. Sci*, 7(5), 1516–1530. <https://2028-2508>
- Abbasi, T., & Abbasi, S. A. (2012). *Water-Quality Indices*. Elsevier. p80. <https://doi.org/978-0-444-54305-9>
- Abdulredha, M. M., Hussain, S. A., & Abdullah, L. C. (2020). Optimization of the demulsification of water in oil emulsion via non-ionic surfactant by the response surface methods. *Journal of Petroleum Science and Engineering*, 184, 106463. <https://doi.org/https://doi.org/10.1016/j.petrol.2019.106463>
- Abdul-Wahab, S. A., & Al-Alawi, S. M. (2002). Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks. *Environmental Modelling & Software*, 17(3), 219–228. [https://doi.org/10.1016/S1364-8152\(01\)00077-9](https://doi.org/10.1016/S1364-8152(01)00077-9)
- Abrahão, R., Carvalho, M., Raimundo Da, W., Júnior, S., Tamara, T., Machado, V., Lúcia, C., Gadelha, M., & Medina Hernandez, M. I. (2007). Use of index analysis to evaluate the water quality of a stream receiving industrial effluents. <http://www.wrc.org.za>

- Ackley, D. H., Hinton, G. E., & Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. *Cognitive Science*, 9(1), 147–169. [https://doi.org/10.1016/S0364-0213\(85\)80012-4](https://doi.org/10.1016/S0364-0213(85)80012-4)
- Adjagodo, A., Agassounon, D. T. M., Kelomè, N. C., Vissin, E. W., & Agbossou, E. (2017). Pollution physique et bactériologique de l'eau du fleuve dans la basse vallée de l'ouémé pendant les périodes de basses et hautes eaux au Bénin. *European Scientific Journal*, 13(33), 167–186. <https://doi.org/10.19044/esj.2017.v13n33p167>
- Ahamad, K., Raj, P., Barbhuiya, N., & Deep, A. (2019). Surface Water Quality Modeling by Regression Analysis and Artificial Neural Network (pp. 215–230). https://doi.org/10.1007/978-981-13-0215-2_15
- Akkaraboyina, M. K., & Raju, B. S. N. (2012). A Comparative Study of Water Quality Indices of River Godavari. In *International Journal of Engineering Research and Development*, 2(3).
- Arab, M., Akbarian, H., Gheibi, M., Akrami, M., Fathollahi-Fard, A. M., Hajiaghaei-Keshteli, M., & Tian, G. (2022). A soft-sensor for sustainable operation of coagulation and flocculation units. *Engineering Applications of Artificial Intelligence*, 115, 105315. <https://doi.org/10.1016/J.ENGAPPAL.2022.105315>
- Aubry, C., Ramamonjisoa, J., Dabat, M.-H., Rakotoarisoa, J., Rakotondraibe, J., & Rabeharisoa, L. (2008). L'agriculture à Antananarivo (Madagascar): une approche interdisciplinaire. *Natures Sciences Sociétés*, 16(1), 23–35. <https://doi.org/10.1051/nss:2008019>
- Azrou, M., Mabrouki, J., Fattah, G., Guezzaz, A., & Aziz, F. (2022). Machine learning algorithms for efficient water quality prediction. *Modeling Earth Systems and Environment*, 8(2), 2793–2801. <https://doi.org/10.1007/s40808-021-01266-6>
- Baccini, A. (2010). *Statistique Descriptive Multidimensionnelle (pour les nuls)*. Publications de l'Institut de Mathématiques de Toulouse, 6.
- Bagastyo, A. Y., Batstone, D. J., Rabaey, K., & Radjenovic, J. (2013). Electrochemical oxidation of electrodialed reverse osmosis concentrate on Ti/Pt–IrO₂, Ti/SnO₂–Sb and boron-doped diamond electrodes. *Water Research*, 47(1), 242–250. <https://doi.org/10.1016/J.WATRES.2012.10.001>

- Bahmanzadegan, F., & Ghaemi, A. (2024). Exploring the effect of zeolite's structural parameters on the CO₂ capture efficiency using RSM and ANN methodologies. *Case Studies in Chemical and Environmental Engineering*, 9, 100595. <https://doi.org/10.1016/J.CSCEE.2023.100595>
- Banas, D., & Lata, J.-C. (2006). Nitrates. The White Paper Pollutants Habitat. In book: *Le livre blanc des polluants de l'habitat*.
- Bardhan, A., & Samui, P. (2022). Probabilistic slope stability analysis of Heavy-haul freight corridor using a hybrid machine learning paradigm. *Transportation Geotechnics*, 37, 100815. <https://doi.org/10.1016/J.TRGEO.2022.100815>
- Barrera-Díaz, C., Linares-Hernández, I., Roa-Morales, G., Bilyeu, B., & Balderas-Hernández, P. (2009). Removal of biorefractory compounds in industrial wastewater by chemical and electrochemical pretreatments. *Industrial & Engineering Chemistry Research*, 48(3), 1253–1258. <https://doi.org/10.1021/ie800560n>
- Barzegar, Y., Gorelova, I., Bellini, F., & D'Ascenzo, F. (2023). Drinking Water Quality Assessment Using a Fuzzy Inference System Method: A Case Study of Rome (Italy). *International Journal of Environmental Research and Public Health*, 20(15), 6522. <https://doi.org/10.3390/ijerph20156522>
- Baumont, S., Camard, J.-P., Lefranc, A., Franconi, A. (2014). Réutilisation des eaux usées épurées : risques sanitaires et faisabilité en Île-de-France. Observatoire régional de santé (Ile-de-France)., and Institut d'aménagement et d'urbanisme d'Île-de-France (1976-2019).
- Bindu, O. S. D. H., Gayathri, V., Swaranya, T., & Vyshnavi, J. (2023). Assessment of ground water quality using water quality index and GIS. *E3S Web of Conferences*, 391, 01208. <https://doi.org/10.1051/e3sconf/202339101208>
- Bliefert, C., & Perraud, R. (2007). *Chimie de l'environnement : air, eau, sols, déchets*. De Boeck Supérieur.477p. <https://doi.org/978-2-8041-5945-0>
- Bloor, J. C., Anderson, G. K., & Willey, A. R. (1995). High-rate aerobic treatment of brewery wastewater using the jet loop reactor. *Water Research*, 29(5), 1217–1223. [https://doi.org/10.1016/0043-1354\(94\)00310-4](https://doi.org/10.1016/0043-1354(94)00310-4)

Blum, D., & Feachem, R. G. (1985). Health aspects of nightsoil and sludge use in agriculture and aquaculture. Part III: An Epidemiological Perspective. IRCWD, Duebendorf, Switzerland.

Bollon, J., Filali, A., Fayolle, Y., Guérin, S., Mottelet, S., Pauss, A., Rocher, V., & Gillot, S. (2016). Optimisation du traitement biologique de l'azote: vers une réduction des intermédiaires réactionnels. 95ème Congrès de l'ASTEE «Territoires En Transition: Mettre l'intelligence Numérique Au Coeur Des Services Publics, 2-p.

Bolmstedt, J. (2000). Dynamic modelling of an activated sludge process at a pulp and paper mill. Lund University, Department of Industrial Electrical Engineering and Automation.

Bouaoune, D., & Dahmani-Megrerouche, M. (2010). Reconstitution de données climatiques pour l'Algérie du Nord: application des réseaux neuronaux. *Comptes Rendus Géoscience*, 342(11), 815–822. <https://doi.org/10.1016/j.crte.2010.09.005>

Braeken, L., Van der Bruggen, B., & Vandecasteele, C. (2004). Regeneration of brewery waste water using nanofiltration. *Water Research*, 38(13), 3075–3082. <https://doi.org/10.1016/j.watres.2004.03.028>

Bruns, R. E., Scarminio, I. S., & de Barros Neto, B. (2006). Statistical design-chemometrics. Volume 25 de Data handling in science and technology, Elsevier. 1st Edition 412p. <https://9780444521811>

Buscema, M. (1998). Back propagation neural networks. In *Substance Use and Misuse*, 33(2), 233–270. Informa Healthcare. <https://doi.org/10.3109/10826089809115863>

Bypour, M., Yekrangnia, M., & Kioumars, M. (2024). Predicting the shear capacity of composite steel plate shear wall with the application of RSM. *Engineering Structures*, 301, 117263. <https://doi.org/10.1016/J.ENGSTRUCT.2023.117263>

Callender, E. (2003). Heavy Metals in the Environment—Historical Trends. *Treatise on Geochemistry*, 9–9, 67–105. <https://doi.org/10.1016/B0-08-043751-6/09161-1>.

Calmuc, M., Calmuc, V., Arseni, M., Topa, C., Timofti, M., Georgescu, L. P., & Iticescu, C. (2020). A comparative approach to a series of physico-chemical quality indices used in assessing water quality in the lower danube. *Water (Switzerland)*, 12(11). <https://doi.org/10.3390/w12113239>

- Calmuc, V. A., Calmuc, M., Arseni, M., Topa, C. M., Timofti, M., Burada, A., Iticescu, C., & Georgescu, L. P. (2021). Assessment of heavy metal pollution levels in sediments and of ecological risk by quality indices, applying a case study: The lower danube river, romania. *Water (Switzerland)*, 13(13). <https://doi.org/10.3390/w13131801>
- Cao, W., Wang, X., Ming, Z., & Gao, J. (2018). A review on neural networks with random weights. *Neurocomputing*, 275, 278–287. <https://doi.org/10.1016/J.NEUCOM.2017.08.040>
- Cervantes, F. J., Pavlostathis, S. G., & van Haandel, A. (2006). Advanced biological treatment processes for industrial wastewaters. IWA publishing. <https://doi.org/10.2166/9781780402345>
- Chan, Y. J., Chong, M. F., Law, C. L., & Hassell, D. G. (2009). A review on anaerobic–aerobic treatment of industrial and municipal wastewater. *Chemical Engineering Journal*, 155(1–2), 1–18. <https://doi.org/10.1016/j.cej.2009.06.041>
- Chaouay, A., Okhrib, R., Hilali, M., Bazzi, L., Chahid, A., & Khiri, F. (2016). Contribution à l'étude de l'analyse physico-chimique et de la contamination métallique de l'eau de mer du littoral d'Agadir (Sud du Maroc). Contribution to the study of physico-chemical analysis and metal contamination of coastal Agadir seawater (South Morocco). *Journal of Materials and Environmental Science*, 7(8), 2748–2759. <https://doi.org/2028-2508>
- Charulatha, G., Srinivasalu, S., Oorkavalan, uma maheswari, T. V., & Giridharan, L. (2017). Evaluation of ground water quality contaminants using linear regression and artificial neural network models. *Arabian Journal of Geosciences*, 10. <https://doi.org/10.1007/s12517-017-2867-6>
- Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. In *Applied Sciences (Switzerland)* (Vol. 10, Issue 17). MDPI AG. <https://doi.org/10.3390/app10175776>
- Chevalier, P., Cordier, S., Dab, W., Gérin, M., Gosselin, P., Quénel, P., Gosselin, P., Viau, C., & Quénel, P. (2003). Santé environnementale. In *Environnement et Santé Publique, fondements et pratiques*. Tec and Doc, Acton Val, Paris. p59–86.
- Commendatore, M. G., & Esteves, J. L. (2004). Natural and anthropogenic hydrocarbons in sediments from the Chubut River (Patagonia, Argentina). *Marine Pollution Bulletin*, 48(9–10), 910–918. <https://doi.org/10.1016/j.marpolbul.2003.11.015>

- Cornuéjols, A., & Miclet, L. (2011). *Apprentissage artificiel : concepts et algorithmes*. Editions Eyrolles ; 4e édition. 990p.
- Coulibaly, P., Anctil, F., & Bobée, B. (1999). Prédiction hydrologique par réseaux de neurones artificiels : état de l'art. *Canadian Journal of Civil Engineering* 26(3):293-304. <https://doi.org/10.1139/cjce-26-3-293>
- Couture, I. (2006). Principaux critères pour évaluer la qualité de l'eau en micro-irrigation. *Colloque Sur l'irrigation, L'eau, Source de Qualité et de Rendement*, 13p, 17.
- Coynel, A., Blanc, G., Marache, A., Schäfer, J., Dabrin, A., Maneux, E., Bossy, C., Masson, M., & Lavaux, G. (2009). Assessment of metal contamination in a small mining-and smelting-affected watershed: high resolution monitoring coupled with spatial analysis by GIS. *Journal of Environmental Monitoring*, 11(5), 962–976. <https://doi.org/10.1039/b818671e>
- Crini, G., Montiel, A. J., & Badot, P.-M. (2007). *Traitement et épuration des eaux industrielles polluées : Procédés membranaires, bioadsorption et oxydation chimique*. Presses Univ. Franche-Comté. <https://doi.org/978-2-84867-197-0>
- Crous, L., & Britz, P. (2010). The use of constructed wetland technology in the treatment and beneficiation of brewery effluent for aquaculture. *Proceeding of the 12th International Conference Wetland Systems for Water Pollution Control*, IWA, IRIDRA Srl and Pan Srl Padova, Italy, 1255–1259.
- Cyr, D., Hausler, R., & Yargeau, V. (2015). *Rapport d'examen par des experts indépendants des renseignements techniques et scientifiques concernant le déversement d'effluent d'eaux usées non traitées dans le fleuve Saint-Laurent prévu par la Ville de Montréal*. <https://doi.org/978-0-660-03784-4>
- Dadolahi-Sohrab, A., Arjomand, F., & Fadaei-Nasab, M. (2012). Water quality index as a simple indicator of watersheds pollution in southwestern part of Iran. *Water and Environment Journal*, 26(4), 445–454. <https://doi.org/10.1111/j.1747-6593.2011.00303.x>
- De Souza, A. T., Carneiro, L. A. T. X., da Silva Junior, O. P., de Carvalho, S. L., & Américo-Pinheiro, J. H. P. (2021). Assessment of water quality using principal component analysis: a case study of the Marrecas stream basin in Brazil. *Environmental Technology*, 42(27), 4286–4295. <https://doi.org/10.1080/09593330.2020.1754922>

- Degrémont, G. (1972). *Mémento technique de l'eau*. Ed. Techniques Ingénieur.
- Dernat, M., & Pouillot, M. (1994). L'action du dioxyde de chlore en préoxydation et en désinfection des eaux. *L'Eau, l'industrie, Les Nuisances*, 172, 44–48.
- Deronzier, G., & Choubert, J.-M. (2004). Traitement du phosphore dans les petites stations d'épuration à boues activées. Document Technique FNDAE, 29. <https://doi.org/2-11-092856-5>
- Devez, A., Gomez, E., Gilbin, R., Elbaz-Poulichet, F., Persin, F., Andrieux, P., & Casellas, C. (2005). Assessment of copper bioavailability and toxicity in vineyard runoff waters by DPASV and algal bioassay. *Science of the Total Environment*, 348(1–3), 82–92. <https://doi.org/10.1016/j.scitotenv.2005.01.004>
- Diab W. (2016). Etude des propriétés physico-chimiques et colloïdales du bassin de la rivière Litani, Liban. Université de Lorraine (France).
- Dialynas, E., Mantzavinos, D., & Diamadopoulos, E. (2008). Advanced treatment of the reverse osmosis concentrate produced during reclamation of municipal wastewater. *Water Research*, 42(18), 4603–4608. <https://doi.org/10.1016/J.WATRES.2008.08.008>
- Divet, L., & Schulhof, P. (1980). *Le traitement des eaux*. FeniXX. 128p.
- Djelal, H., Rigail, M., & Boyer, L. (2008). Les effluents industriels et leur traitement. *Management & Avenir*, n° 20(6), 275–288. <https://doi.org/10.3917/mav.020.0275>
- Dreyfus, G. (1998). Les réseaux de neurones. *Mécanique industrielle et matériaux*, n°51.19p.
- Driessen, W., & Vereijken, T. (2003). Recent developments in biological treatment of brewery effluent. The Institute and Guild of Brewing Convention, Livingstone, Zambia, March, 2–7.
- Duby, C., & Robin, S. (2006). *Analyse en composantes principales*. Institut National Agronomique, Paris-Grignon, 80, 53.
- Dumat, C., Xiong, T., & Shahid, M. (2016). Agriculture urbaine durable : opportunité pour la transition écologique. Presses Universitaires Européennes. <https://doi.org/978-3-639-69662-2>

Édouard, R. (2021). Évaluation des impacts des eaux industrielles sur la rivière TROU-DU-NORD.

El Yousfi, Y., Himi, M., El Ouarghi, H., Aqnouy, M., Benyoussef, S., Gueddari, H., Ait Hmeid, H., Alitane, A., Chaibi, M., Zahid, M., Essahlaoui, N., Hitouri, S., Essahlaoui, A., & Elaaraj, A. (2023). Assessment and Prediction of the Water Quality Index for the Groundwater of the Ghiss-Nekkor (Al Hoceima, Northeastern Morocco). *Sustainability (Switzerland)*, 15(1). <https://doi.org/10.3390/su15010402>

Elemile, O. O., Ibitogbe, E. M., Folorunso, O. P., Ejiboye, P. O., & Adewumi, J. R. (2021). Principal component analysis of groundwater sources pollution in Omu-Aran Community, Nigeria. *Environmental Earth Sciences*, 80(20), 690. <https://doi.org/10.1007/s12665-021-09975-y>

Emmanuel, O. A., & Olalekan, A. M. B. (2008). COD removal from industrial wastewater using activated carbon prepared from animal horns. *African Journal of Biotechnology*, 7(21), 3887–3891. <https://doi.org/1684-5315>

Fanoodi, B., Malmir, B., & Jahantigh, F. F. (2019). Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models. *Computers in Biology and Medicine*, 113, 103415. <https://doi.org/10.1016/J.COMPBIOMED.2019.103415>

Feachem, R. G., Feachem, R. G. A., Bradley, D. J., Garelick, H., & Mara, D. D. (1983). *Sanitation and disease: health aspects of excreta and wastewater management (Vol. 1)*. Wiley New York. <https://doi.org/0-471-90094-X>

Fonge, A. B., Chuyong, B. G., Tening, A. S., Fobid, A. C., & Numbisi, N. F. (2013). Seasonal occurrence, distribution and diversity of phytoplankton in the Douala Estuary, Cameroon. *African Journal of Aquatic Science*, 38(2), 123–133. <https://doi.org/10.2989/16085914.2013.769086>

Foucard, P., Tocqueville, A., Gaumé, M., Labbé, L., Baroiller, J.-F., Lejolivet, C., & Darfeuille, B. (2019). Potentiel de développement de l'aquaponie en France: Le programme apiva® "Aquaponie Innovation Végétale et Aquaculture." *Innovations Agronomiques*, 71, 385–400. <https://doi.org/hal-02622409>

- Gaya, M. S., Abba, S. I., Abdu, A. M., Tukur, A. I., Saleh, M. A., Esmaili, P., & Wahab, N. A. (2020). Estimation of water quality index using artificial intelligence approaches and multi-linear regression. *IAES International Journal of Artificial Intelligence*, 9(1), 126–134. <https://doi.org/10.11591/ijai.v9.i1.pp126-134>
- Gazzaz, Dr. N. (2012). Characterization of Spatial Patterns in River Water Quality Using Chemometric Pattern Recognition Techniques. *Marine Pollution Bulletin*, 64, 688–698. <https://doi.org/10.1016/j.marpolbul.2012.01.032>
- Genin, B., Chauvin, C., & Ménard, F. (2003). Cours d'eau et indices biologiques : pollution, méthodes, IBGN. Educagri éditions. <https://doi.org/2-84444-272-2>
- Georgescu, P. L., Moldovanu, S., Iticescu, C., Calmuc, M., Calmuc, V., Topa, C., & Moraru, L. (2023). Assessing and forecasting water quality in the Danube River by using neural network approaches. *Science of the Total Environment*, 879. <https://doi.org/10.1016/j.scitotenv.2023.162998>
- Ghaemi, A., Karimi Dehnavi, M., & Khoshraftar, Z. (2023). Exploring artificial neural network approach and RSM modeling in the prediction of CO₂ capture using carbon molecular sieves. *Case Studies in Chemical and Environmental Engineering*, 7, 100310. <https://doi.org/10.1016/J.CSCEE.2023.100310>
- Gharib, S. M., El-Sherif, Z. M., Abdel-Halim, A. M., & Radwan, A. A. (2011). Phytoplankton and environmental variables as a water quality indicator for the beaches at Matrouh, south-eastern Mediterranean Sea, Egypt: An assessment. *Oceanologia*, 53(3), 819–836. <https://doi.org/10.5697/oc.53-3.819>
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation. *Journal of Intelligent Technologies and Applied Statistics*, 11(2), 105-111. https://scholarworks.utep.edu/cs_techrep/1209
- Gilmour, S. G. (2006). Response surface designs for experiments in bioprocessing. *Biometrics*, 62(2), 323–331. <https://doi.org/10.1111/j.1541-0420.2005.00444.x>
- Girard, M.-C., Schwartz, C., & Jabiol, B. (2011). Etude des sols : description, cartographie, utilisation. Dunod. 416 p. <https://9782100569540>

- Gomm, J. B. (1996). On-line learning for fault classification using an adaptive neuro-fuzzy network. *IFAC Proceedings Volumes*, 29(1), 6494–6499. [https://doi.org/10.1016/S1474-6670\(17\)58724-8](https://doi.org/10.1016/S1474-6670(17)58724-8)
- Graham, T. (1861). X. Liquid diffusion applied to analysis. *Philosophical Transactions of the Royal Society of London*, 151, 183–224. <https://doi.org/10.1098/rstl.1861.0011>
- Hade, A. (2003). *Nos lacs : les connaître pour mieux les protéger*. Les Editions Fides. 359 p. <https://9782762125344>
- Hameed, M., Sharqi, S., Yaseen, Z., Afan, H., Hussain, A., & Elshafie, A. (2017). Application of artificial intelligence (AI) techniques in water quality index prediction: a case study in tropical region, Malaysia. *Neural Computing and Applications*, 28. <https://doi.org/10.1007/s00521-016-2404-7>
- Hamzehie, M. E., Mazinani, S., Davardoost, F., Mokhtare, A., Najibi, H., Van der Bruggen, B., & Darvishmanesh, S. (2014). Developing a feed forward multilayer neural network model for prediction of CO₂ solubility in blended aqueous amine solutions. *Journal of Natural Gas Science and Engineering*, 21, 19–25. <https://doi.org/10.1016/J.JNGSE.2014.07.022>
- Hartemann, P. (2004). Contamination des eaux en milieu professionnel. *EMC-Toxicologie-Pathologie*, 1(2), 63–78. <https://doi.org/10.1016/j.emctp.2003.12.002>
- Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Pearson Education India. <https://doi.org/2008034079>
- Hayzoun, H., Garnier, C., Durrieu, G., Lenoble, V., Le Poupon, C., Angeletti, B., Ouammou, A., & Mounier, S. (2015). Organic carbon, and major and trace element dynamic and fate in a large river subjected to poorly regulated urban and industrial pressures (Sebou River, Morocco). *Science of The Total Environment*, 502, 296–308. <https://doi.org/10.1016/J.SCITOTENV.2014.09.014>
- Hebb, D. O. (1949). *Organization of behavior*. new york: Wiley. *J. Clin. Psychol*, 6(3), 307–335. [https://doi.org/10.1016/s0361-9230\(99\)00182-3](https://doi.org/10.1016/s0361-9230(99)00182-3)

- Henze, M., Gujer, W., Mino, T., & Van Loosedrecht, M. (2006). Activated sludge models ASM1, ASM2, ASM2d and ASM3. <https://doi.org/10.2166/9781780402369>
- Heo, S., & Lee, J. H. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 51(18), 470–475. <https://doi.org/10.1016/J.IFACOL.2018.09.380>
- Hill, J. M., & Helz, G. R. (1973). Copper and zinc in estuarine waters near a coal-fired electric power plant—correlation with oyster greening. *Environmental Letters*, 5(3), 165–174. <https://doi.org/10.1080/00139307309435523>
- 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. <https://doi.org/10.1073/pnas.79.8.2554>
- Hore, A., Dutta, S., Datta, S., & Bhattacharjee, C. (2008). Application of an artificial neural network in wastewater quality monitoring: Prediction of water quality index. *International Journal of Nuclear Desalination*, 3. <https://doi.org/10.1504/IJND.2008.020223>
- Horton, R. K. (1965). An index-number system for rating water quality. *Journal of the Water Pollution Control Federation*, 37, 300–306. [http://www.scirp.org/\(S\(i43dyn45teexjx455qlt3d2q\)\)/reference/Ref](http://www.scirp.org/(S(i43dyn45teexjx455qlt3d2q))/reference/Ref)
- Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24(6), 417. <https://doi.org/10.1037/h0071325>
- Hounsounou, E. O., Tchiboza, M. A. D., Kelome, N. C., Vissin, E. W., Mensah, G. A., & Agbossou, E. (2016). Pollution des eaux à usages domestiques dans les milieux urbains défavorisés des pays en développement : Synthèse bibliographique. *International Journal of Biological and Chemical Sciences*, 10(5), 2392–2412. <http://dx.doi.org/10.4314/ijbcs.v10i5.35>
- Imran, B., Khan, S. J., Qazi, I. A., & Arshad, M. (2016). Removal and recovery of sodium hydroxide (NaOH) from industrial wastewater by two-stage diffusion dialysis (DD) and electro dialysis (ED) processes. *Desalination and Water Treatment*, 57(17), 7926–7932. <https://doi.org/10.1080/19443994.2015.1048742>

- Ince, B. K., Ince, O., Sallis, P. J., & Anderson, G. K. (2000). Inert COD production in a membrane anaerobic reactor treating brewery wastewater. *Water Research*, 34(16), 3943–3948. [https://doi.org/10.1016/S0043-1354\(00\)00170-6](https://doi.org/10.1016/S0043-1354(00)00170-6)
- Inobeme, A., Nayak, V., Mathew, T. J., Okonkwo, S., Ekwoba, L., Ajai, A. I., Bernard, E., Inobeme, J., Agbugui, M. M., & Singh, K. R. B. (2022). Chemometric approach in environmental pollution analysis: A critical review. *Journal of Environmental Management*, 309, 114653. <https://doi.org/10.1016/j.jenvman.2022.114653>
- Ismail, E., Snousy, M. G., Alexakis, D. E., Abdelhalim, A., Ahmed, M. S., & Elsayed, E. (2023). Diagnosis of Groundwater Quality in North Assiut Province, Egypt, for Drinking and Irrigation Uses by Applying Multivariate Statistics and Hydrochemical Methods. *Water*, 15(15), 2812. <https://doi.org/10.3390/w15152812>
- Iticescu, C., Georgescu, L. P., Murariu, G., Topa, C., Timofti, M., Pintilie, V., & Arseni, M. (2019). Lower danube water quality quantified through WQI and multivariate analysis. *Water (Switzerland)*, 11(6). <https://doi.org/10.3390/w11061305>
- Iticescu, C., Murariu, G., Georgescu, L. P., Burada, A., & Topa, C. M. (2016). Seasonal Variation of the Physico-chemical Parameters and Water Quality Index (WQI) of Danube Water in the Transborder Lower Danube Area. In *REV.CHIM.(Bucharest)*♦ (Vol. 67, Issue 9). <http://www.revistadechimie.ro1843>
- Jaiyeola, A. T., & Bwapwa, J. K. (2016). Treatment technology for brewery wastewater in a water-scarce country: A review. *South African Journal of Science*, 112(3–4), 1–8. <https://doi.org/10.17159/sajs.2016/20150069>
- James, W. (1984). *Psychology, briefer course* (Vol. 14). Harvard University Press.
- Jana, D. K., Bhunia, P., Das Adhikary, S., & Bej, B. (2022). Optimization of Effluents Using Artificial Neural Network and Support Vector Regression in Detergent Industrial Wastewater Treatment. *Cleaner Chemical Engineering*, 3, 100039. <https://doi.org/10.1016/j.clce.2022.100039>
- Javed, S., Ali, A., & Ullah, S. (2017). Spatial assessment of water quality parameters in Jhelum city (Pakistan). *Environmental Monitoring and Assessment*, 189. <https://doi.org/10.1007/s10661-017-5822-9>

- Jian, B. T. P., Mustafa, M. R. U., Isa, M. H., Yaqub, A., & Chia, H. Y. (2020). Study of the water quality index and polycyclic aromatic hydrocarbon for a river receiving treated landfill leachate. *Water (Switzerland)*, 12(10), 1–29. <https://doi.org/10.3390/w12102877>
- Joo, S. H., & Tansel, B. (2015). Novel technologies for reverse osmosis concentrate treatment: A review. *Journal of Environmental Management*, 150, 322–335. <https://doi.org/10.1016/J.JENVMAN.2014.10.027>
- JORA. (2006). Official Journal of the Algerian Republic No. 26 of April 23, Annex 1, which defines the permissible limit values for industrial liquid effluent discharge parameters.
- Joshi, D. M., Kumar, A., & Agrawal, N. (2009). Assessment Of The Irrigation Water Quality Of River Ganga In Haridwar District. 2(2), 285–292. <http://www.rasayanjournal.com>
- Juahir, H., Zain, S. M., Aris, A. Z., Yusoff, M. K., & Mokhtar, M. Bin. (2010). Spatial assessment of Langat river water quality using chemometrics. *Journal of Environmental Monitoring*, 12(1), 287–295. <https://doi.org/10.1039/b907306j>
- Kachroud, M., Trolard, F., Kefi, M., Jebari, S., & Bourrié, G. (2019). Water quality indices: Challenges and application limits in the literature. *Water (Switzerland)*, 11(2). <https://doi.org/10.3390/w11020361>
- Kadam, A. K., Wagh, V. M., Muley, A. A., Umrikar, B. N., & Sankhua, R. N. (2019). Prediction of water quality index using artificial neural network and multiple linear regression modelling approach in Shivganga River basin, India. *Modeling Earth Systems and Environment*, 5(3), 951–962. <https://doi.org/10.1007/s40808-019-00581-3>
- Kannel, P. R., Lee, S., Lee, Y. S., Kanel, S. R., & Khan, S. P. (2007). Application of water quality indices and dissolved oxygen as indicators for river water classification and urban impact assessment. *Environmental Monitoring and Assessment*, 132(1–3), 93–110. <https://doi.org/10.1007/s10661-006-9505-1>
- Kern, P., Wolf, C., Gaida, D., Bongards, M., & Mcloone, S. (2014). COD and NH₄-N Estimation in the Inflow of Wastewater Treatment Plants using Machine Learning Techniques. In *IEEE International Conference on Automation Science and Engineering (Vol. 2014)*. <https://doi.org/10.1109/CoASE.2014.6899419>
- Kharroubi, O., Blanpain, O., Masson, E., & Lallahem, S. (2016). Application du réseau des neurones artificiels à la prévision des débits horaires: Cas du bassin versant de l'Eure,

France. Hydrological Sciences Journal, 61(3), 541–550.
<https://doi.org/10.1080/02626667.2014.933225>

Khayet, M., Cojocaru, C., & Essalhi, M. (2011). Artificial neural network modeling and response surface methodology of desalination by reverse osmosis. *Journal of Membrane Science*, 368(1–2), 202–214. <https://doi.org/10.1016/J.MEMSCI.2010.11.030>

Khosravi, K., Rezaie, F., Cooper, J. R., Kalantari, Z., Abolfathi, S., & Hatamiafkoueieh, J. (2023). Soil water erosion susceptibility assessment using deep learning algorithms. *Journal of Hydrology*, 618, 129229. <https://doi.org/10.1016/J.JHYDROL.2023.129229>

Kohonen, T. (2012). *Self-organization and associative memory* (Vol. 8). Springer Science & Business Media.

Koller, E. (2004). *Traitement des pollutions industrielles : eau, air, déchets, sols, boues*. Dunod Paris, France.

Koné, M. D. (2011). Infiltration-percolation sur sable et sur fibre de coco, filtres plantes et épuration d'eaux usées domestiques à dominance agroalimentaire sous climat tropical sec: cas des eaux résiduaires urbaines de Ouagadougou, Burkina Faso. *Sciences Appliquées*.

Kotsiantis, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. *In Informatica*, 31, 249-268.

Kouadri, S., Kateb, S., & Zegait, R. (2021). Spatial and temporal model for WQI prediction based on back-propagation neural network, application on EL MERK region (Algerian southeast). *Journal of the Saudi Society of Agricultural Sciences*, 20(5), 324–336. <https://doi.org/10.1016/j.jssas.2021.03.004>

Krtolica, I., Cvijanović, D., Obradović, Đ., Novković, M., Milošević, D., Savić, D., Vojinović-Miloradov, M., & Radulović, S. (2021). Water quality and macrophytes in the Danube River: Artificial neural network modelling. *Ecological Indicators*, 121. <https://doi.org/10.1016/j.ecolind.2020.107076>

Kulisz, M., & Kujawska, J. (2021). Application of artificial neural network (ANN) for water quality index (WQI) prediction for the river Warta, Poland. *Journal of Physics: Conference Series*, 2130(1). <https://doi.org/10.1088/1742-6596/2130/1/012028>

- Kulisz, M., Kujawska, J., Przysucha, B., & Cel, W. (2021). Forecasting water quality index in groundwater using artificial neural network. *Energies*, 14(18). <https://doi.org/10.3390/en14185875>
- Larrose, A. (2011). Quantification and spatial distribution of trace element contamination in the Gironde fluvio-estuarine system. https://inis.iaea.org/search/search.aspx?orig_q=RN:51092026
- Le Cun, Y. (2019). *Quand la machine apprend : la révolution des neurones artificiels et de l'apprentissage profond*. Odile Jacob.
- Lek, S., & Guegan, J. F. (1999). Application of artificial neural networks in ecological modelling. In *International Journal on Ecological Modelling and Systems Ecology* (Vol. 120, Issue 3). www.c1scvler.com/locatc/ccomodcl
- Lepper, P. (2005). *Manual on the methodological framework to derive environmental quality standards for priority substances in accordance with Article 16 of the Water Framework Directive (2000/60/EC)*. Schmallenberg, Germany: Fraunhofer-Institute Molecular Biology and Applied Ecology, 15, 51–52.
- Li, N., Ning, Z., Chen, M., Wu, D., Hao, C., Zhang, D., Bai, R., Liu, H., Chen, X., & Li, W. (2022). Satellite and Machine Learning Monitoring of Optically Inactive Water Quality Variability in a Tropical River. *Remote Sensing*, 14(21), 5466. <https://doi.org/10.3390/rs14215466>
- Li, S., Chen, X., Singh, V. P., He, Y., & Bai, X. (2019). An improved index for water quality evaluation in an estuary region: A case study in the Eastern Pearl River Delta, China. *Water Policy*, 21(2), 310–325. <https://doi.org/10.2166/wp.2019.151>
- Liang, F., Sun, L., Zeng, Z., & Kang, J. (2023). Treatment of surfactant wastewater by foam separation: Combining the RSM method and WOA-BP neural network to explore optimal process conditions. *Chemical Engineering Research and Design*, 193, 85–98. <https://doi.org/https://doi.org/10.1016/j.cherd.2023.03.023>
- Livingstone, D. M. (1991). The diel oxygen cycle in three subalpine Swiss streams. *Archiv Für Hydrobiologie*, 457–479. <https://doi.org/10.1127/archiv-hydrobiol/120/1991/457>
- Lucas, M. S., Peres, J. A., & Puma, G. L. (2010). Treatment of winery wastewater by ozone-based advanced oxidation processes (O₃, O₃/UV and O₃/UV/H₂O₂) in a pilot-scale bubble

- column reactor and process economics. *Separation and Purification Technology*, 72(3), 235–241. <https://doi.org/10.1016/j.seppur.2010.01.016>
- Lumb, A., Sharma, T. C., & Bibeault, J.-F. (2011). A review of genesis and evolution of water quality index (WQI) and some future directions. *Water Quality, Exposure and Health*, 3, 11–24. <https://doi.org/10.1007/s12403-011-0040-0>
- Mama, A. C., Bodo, W. K. A., Ghepdeu, G. F. Y., Ajonina, G. N., & Ndam, J. R. N. (2021). Understanding Seasonal and Spatial Variation of Water Quality Parameters in Mangrove Estuary of the Nyong River Using Multivariate Analysis (Cameroon Southern Atlantic Coast). *Open Journal of Marine Science*, 11(03), 103–128. <https://doi.org/10.4236/ojms.2021.113008>
- Manoiu, V.-M., & Crăciun, A.-I. (2021). Danube River Water Quality Trends: a Qualitative Review Based on the Open Access Web of Science Database. *Ecohydrology & Hydrobiology*, 21. <https://doi.org/10.1016/j.ecohyd.2021.08.002>
- Marchand, M., & Martin, J. L. (1985). Détermination de la pollution chimique (hydrocarbures, organochlorés, métaux) dans la lagune d'Abidjan (Côte d'Ivoire) par l'étude des sédiments. *Océanogr. Trop*, 20(1), 23–39.
- Mcculloch, W. S., & Pitts, W. (1990). A Logical Calculus Of The Ideas Immanent In Nervous Activity. In *Bulletin of Mothemnticnl Biology* (Vol. 52, Issue 2). <https://doi.org/2185863>
- Meerganz von Medeazza, G. L. (2005). “Direct” and socially-induced environmental impacts of desalination. *Desalination*, 185(1–3), 57–70. <https://doi.org/10.1016/J.DESAL.2005.03.071>
- Meinck, F., Stooff, H., & Kohlschütter, H. (1977). *Les eaux résiduaires industrielles*. 2e Éd. Masson, Paris, France, 863p.
- Mellal, N. E. H., Tahar, W., Boumaaza, M., Belaadi, A., & Bourchak, M. (2024). Prediction of purified water quality in industrial hydrocarbon wastewater treatment using an artificial neural network and response surface methodology. *Journal of Water Process Engineering*, 58, 104757. <https://doi.org/10.1016/j.jwpe.2023.104757>.

- Melloul, A. A., & Hassani, L. (1999). Salmonella infection in children from the wastewater-spreading zone of Marrakesh city (Morocco). *Journal of Applied Microbiology*, 87(4), 536–539. <https://doi.org/10.1046/j.1365-2672.1999.00847.x>
- Menoret, C. (2001). Traitement d'effluents concentrés par cultures fixées sur gravier ou pouzzolane. Université Montpellier II Sciences Et Techniques Du Languedoc.
- Mercier, T., Dembélé, A., Denoeux, T., & BLANC, P. (2019). Machine Learning As A Decision Support Tool For Wastewater Treatment Plant Operation. <https://doi.org/10.2495/WRM190101>
- Minsky, M. L., & Papert, S. A. (1988). *Perceptrons: expanded edition*. MIT press.
- Mohamed, A. M. O., Maraqa, M., & Al Handhaly, J. (2005). Impact of land disposal of reject brine from desalination plants on soil and groundwater. *Desalination*, 182(1–3), 411–433. <https://doi.org/10.1016/J.DESAL.2005.02.035>.
- Mohammed, N., Palaniandy, P., Shaik, F., Mewada, H., & Balakrishnan, D. (2023). Comparative studies of RSM Box-Behnken and ANN-Anfis fuzzy statistical analysis for seawater biodegradability using TiO₂ photocatalyst. *Chemosphere*, 314, 137665. <https://doi.org/10.1016/J.CHEMOSPHERE.2022.137665>
- Mokhtari, H., Bagheri, M., Mirbagheri, S., & Akbari, A. (2020). Performance evaluation and modelling of an integrated municipal wastewater treatment system using neural networks. *Water and Environment Journal*, 34. <https://doi.org/10.1111/wej.12565>
- Morin-Crini, N., Crini, G., & Roy, Laurent. (2017). Eaux industrielles contaminées : réglementation, paramètres chimiques et biologiques & procédés d'épuration innovants. <https://doi.org/978-2-84867-197>
- Morin-Crini, N., Lichtfouse, E., Fourmentin, M., Ribeiro, A. R. L., Noutsopoulos, C., Mapelli, F., Fenyvesi, É., Vieira, M. G. A., Picos-Corrales, L. A., & Moreno-Piraján, J. C. (2022). Removal of emerging contaminants from wastewater using advanced treatments. A review. *Environmental Chemistry Letters*, 20(2), 1333–1375. <https://doi.org/10.1007/s10311-021-01379-5>
- Mottahedin, P., & Abdoos Amir. (2021). Evaluation of Hablehroud River Water Quality Using Conventional Parameters (IRWQISC)-Iran Water Quality Index for Surface Water Resources and Response Surface Methodology. <https://20.1001.1.17352347.1400.17.3.23.8>

- Mourabet, M., El Rhilassi, A., El Boujaady, H., Bennani-Ziatni, M., & Taitai, A. (2017). Use of response surface methodology for optimization of fluoride adsorption in an aqueous solution by Brushite. *Arabian Journal of Chemistry*, 10, S3292–S3302. <https://doi.org/10.1016/J.ARABJC.2013.12.028>
- Mu'azu, N. D., & Olatunji, S. O. (2023). K-nearest neighbor based computational intelligence and RSM predictive models for extraction of Cadmium from contaminated soil. *Ain Shams Engineering Journal*, 14(4), 101944. <https://doi.org/10.1016/j.asej.2022.101944>
- Najafzadeh, M., & Basirian, S. (2023). Evaluation of River Water Quality Index Using Remote Sensing and Artificial Intelligence Models. *Remote Sensing*, 15(9). <https://doi.org/10.3390/rs15092359>
- Najah, A.-M., El-Shafie, A., Karim, O. A., & Jaafar, O. (2011). An application of different artificial intelligences techniques for water quality prediction. Article in *International Journal of the Physical Sciences*. <https://doi.org/10.5897/IJPS11.1180>
- Namèche, T., & Vassel, J. L. (1999). Bilan thermique sous climat tempéré des lagunes aérées et naturelles. *Revue Des Sciences de l'eau*, 12(1), 65–91. <https://doi.org/10.7202/705344ar>
- Nasir, N., Kansal, A., Alshaltone, O., Barneih, F., Sameer, M., Shanableh, A., & Al-Shamma'a, A. (2022). Water quality classification using machine learning algorithms. *Journal of Water Process Engineering*, 48. <https://doi.org/10.1016/j.jwpe.2022.102920>
- Nayak, J. G., Patil, L. G., & Patki, V. K. (2021). Artificial neural network-based water quality index (WQI) for river Godavari (India). *Materials Today: Proceedings*, 81(2), 212–220. <https://doi.org/10.1016/j.matpr.2021.03.100>
- Newhart, K. B., Marks, C. A., Rauch-Williams, T., Cath, T. Y., & Hering, A. S. (2020). Hybrid statistical-machine learning ammonia forecasting in continuous activated sludge treatment for improved process control. *Journal of Water Process Engineering*, 37. <https://doi.org/10.1016/j.jwpe.2020.101389>
- Ngô, C., & Régent, A. (2012). *Déchets, effluents et pollution-Impact sur l'environnement et la santé*. 3^{ème} édition, Dunod.
- Nguyen, T. G., & Huynh, T. H. N. (2022). Assessment of surface water quality and monitoring in southern Vietnam using multicriteria statistical approaches. *Sustainable Environment Research*, 32(1). <https://doi.org/10.1186/s42834-022-00133-y>

- Nguyen, X. C., Nguyen, T. T. H., Tran, Q. B., Bui, X. T., Ngo, H. H., & Nguyen, D. D. (2022). Artificial intelligence for wastewater treatment. In *Current Developments in Biotechnology and Bioengineering: Advances in Biological Wastewater Treatment Systems* (pp. 587–608). Elsevier. <https://doi.org/10.1016/B978-0-323-99874-1.00008-7>
- Niu, G., Yi, X.-H., Chen, C., Li, X., Han, D., Yan, B., Huang, M., & Ying, G. (2020). A novel effluent quality predicting model based on genetic-deep belief network algorithm for cleaner production in a full-scale paper-making wastewater treatment. *Journal of Cleaner Production*, 265, 121787. <https://doi.org/10.1016/j.jclepro.2020.121787>
- Nourani, V., Elkiran, G., & Abba, S. I. (2018). Wastewater treatment plant performance analysis using artificial intelligence - An ensemble approach. *Water Science and Technology*, 78(10), 2064–2076. <https://doi.org/10.2166/wst.2018.477>
- O'Connor, D. J., & Di Toro, D. M. (1970). Photosynthesis and oxygen balance in streams. *Journal of the Sanitary Engineering Division*, 96(2), 547–571. <https://doi.org/10.1061/JSEDAI.0001093>.
- Olden, J. D., & Jackson, D. A. (2001). Fish–habitat relationships in lakes: Gaining predictive and explanatory insight by using artificial neural networks. *Transactions of the American Fisheries Society*, 130(5), 878–897. [https://doi.org/10.1577/1548-8659\(2001\)130<0878:FHRILG>2.0.CO;2](https://doi.org/10.1577/1548-8659(2001)130<0878:FHRILG>2.0.CO;2)
- Ongley, E. D. (1996). Control of water pollution from agriculture. Volume 55 de Bulletin FAO d'irrigation et de drainage. Food & Agriculture Org. 101 p. <https://doi.org/0254-5284>
- Parizeau, M. (2004). Réseaux de neurones. GIF-21140 et GIF-64326, 124.
- Pashaei, H., Mashhadimoslem, H., & Ghaemi, A. (2023). Modeling and optimization of CO₂ mass transfer flux into Pz-KOH-CO₂ system using RSM and ANN. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-30856-w>
- Paun, I., Chiriac, F. L., Marin, N. M., Cruceru, L. V., Pascu, L. F., Lehr, C. B., & Ene, C. (2017). Water quality index, a useful tool for evaluation of danube river raw water. *Revista de Chimie*, 68(8), 1732–1739. <https://doi.org/10.37358/rc.17.8.5754>
- Pearson, K. (1901). LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2(11), 559–572. <https://doi.org/10.1080/14786440109462720>

- Pérez, G., Fernández-Alba, A. R., Urtiaga, A. M., & Ortiz, I. (2010). Electro-oxidation of reverse osmosis concentrates generated in tertiary water treatment. *Water Research*, 44(9), 2763–2772. <https://doi.org/10.1016/J.WATRES.2010.02.017>.
- Picos-Benítez, A. R., López-Hincapié, J. D., Chávez-Ramírez, A. U., & Rodríguez-García, A. (2017). Artificial intelligence-based model for optimization of COD removal efficiency of an up-flow anaerobic sludge blanket reactor in the saline wastewater treatment. *Water Science and Technology*, 75(6), 1351–1361. <https://doi.org/10.2166/wst.2017.005>
- Prieur, D. (2014). Les bactéries de l'extrême. De Boeck Supérieur. p 190. <https://doi.org/978-2-8041-8824-5>
- Prost, A., & Boutin, P. (1989). Sanitary risk resulting from the agricultural reuse of urban wastewater. *TECH. SCI. METHODES.*, 84(1), 25–33.
- Qin, L., Liu, Q., Meng, Q., Fan, Z., He, J., Liu, T., Shen, C., & Zhang, G. (2017). Anoxic oscillating MBR for photosynthetic bacteria harvesting and high salinity wastewater treatment. *Bioresource Technology*, 224, 69–77. <https://doi.org/10.1016/j.biortech.2016.10.067>
- Radović, S., Pap, S., & Sekulić, M. T. (2022). Machine Learning As a Support Tool in Wastewater Treatment Systems—a Short Review. In *Int. Symp. Graph. Eng. Des.* (pp. 799-807). <https://doi.org/10.24867/GRID-2022-p89>
- Rahgoshay, M., Feiznia, S., Arian, M., & Hashemi, S. A. A. (2018). Modeling daily suspended sediment load using improved support vector machine model and genetic algorithm. *Environmental Science and Pollution Research*, 25, 35693–35706. <https://doi.org/10.1007/s11356-018-3533-6>
- Ramakrishnaiah, C. R., Sadashivaiah, C., & Ranganna, G. (2009). Assessment of water quality index for the groundwater in Tumkur Taluk, Karnataka State, India. *E-Journal of Chemistry*, 6(2), 523–530. <https://doi.org/10.1155/2009/757424>
- Rejsek, F. (2002) *Analyse des eaux: Aspects réglementaires et techniques*. Scéren (CRDP AQUITAINE). Coll. Biologie technique. Sciences et techniques de l'environnement. 360p.
- Rodier, J., Legube, B., Merlet, N., & et Coll. (2009). *Analyse de l'eau*. Ed. DUNOD, Paris. <https://doi.org/9782100072460>

- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Rouamba, J., Nikiema, E., Rouamba, S., & De Charles Ouedraogo, F. (2016). Accès à l'eau potable et risques sanitaires en zone périphérique de Ouagadougou, Burkina Faso. *Revue d'Épidémiologie et de Santé Publique*, 64, S211. <https://doi.org/10.1016/j.respe.2016.06.110>
- Roy, R., Majumder, M., & Barman, R. N. (2017). Assessment of Water Quality by RSM and ANP: A Case Study in Tripura, India. *Asian Journal of Water, Environment and Pollution*, 14(1), 51–58. <https://doi.org/10.3233/AJW-170006>
- Rufina R, D. J., Uthayakumar, H., & Thangavelu, P. (2023). Prediction of the size of green synthesized silver nanoparticles using RSM-ANN-LM hybrid modeling approach. *Chemical Physics Impact*, 6. <https://doi.org/10.1016/j.chphi.2023.100231>
- Sachon, G. (1980). L'industrie laitière et la pollution des eaux (2. Partie) [France]. *Revue des-Ecoles-d'Industrie-Laitière (France)*. (n°51) p. 21-28. <https://doi.org/0395-6865>
- Safeer, S., Pandey, R. P., Rehman, B., Safdar, T., Ahmad, I., Hasan, S. W., & Ullah, A. (2022). A review of artificial intelligence in water purification and wastewater treatment: Recent advancements. *Journal of Water Process Engineering*, 49, 102974. <https://doi.org/10.1016/J.JWPE.2022.102974>
- Saffran, K., Cash, K., Hallard, K., & Wright, R. (2001). Canadian water quality guidelines for the protection of aquatic life, CCME water quality Index 1, 0, User's manual. Excerpt from Publication, 1299.
- Salas, J. D., & Smith, R. A. (1981). Physical basis of stochastic models of annual flows. *Water Resources Research*, 17(2), 428–430. <https://doi.org/0043-1397/81/080W-1355501.00>
- Salman Dawood, A., Hussain Al Bremani, H. K., Alak Hassan, A., Hussain, H. K., & Hassan, A. (2016). Modeling of River Water Quality Parameters Using Artificial Neural Network-A Case Study. In *International Journal of Advances in Mechanical and Civil Engineering (Issue 3)*. <https://www.researchgate.net/publication/319465140>

- Salomon, J.-N. (2003). *Danger pollutions !* Presses Univ de Bordeaux. DOI : <https://doi.org/10.4000/books.pub.1296>
- Sawadogo, B. (2018). *Traitement des eaux usées industrielles par des procédés membranaires sous climat sahélien : cas des eaux usées de brasserie au Burkina Faso.* Université Montpellier. <https://doi.org/2018MONTG085>
- Schaechter, M., Medoff, G., & Eisenstein, B. I. (1999). *Microbiologie et pathologie infectieuse.* De Boeck Supérieur. <https://doi.org/2-8041-1592-5>
- Setshedi, K. J., Mutingwende, N., & Ngqwala, N. P. (2021). The Use of Artificial Neural Networks to Predict the Physicochemical Characteristics of Water Quality in Three District Municipalities, Eastern Cape Province, South Africa. <https://doi.org/10.3390/10.3390/ijerph18105248>
- Shalaby, A., Elkamel, A., Douglas, P. L., Zhu, Q., & Zheng, Q. P. (2021). A machine learning approach for modeling and optimization of a CO₂ post-combustion capture unit. *Energy*, 215, 119113. <https://doi.org/10.1016/J.ENERGY.2020.119113>
- Shanmuganathan, S., Loganathan, P., Kazner, C., Johir, M. A. H., & Vigneswaran, S. (2017). Submerged membrane filtration adsorption hybrid system for the removal of organic micropollutants from a water reclamation plant reverse osmosis concentrate. *Desalination*, 401, 134–141. <https://doi.org/10.1016/J.DESAL.2016.07.048>
- Sharafati, A., H.S. Asadollah, B., & Hosseinzadeh, M. (2020). The potential of new ensemble machine learning models for effluent quality parameters prediction and related uncertainty. *Process Safety and Environmental Protection*, 140. <https://doi.org/10.1016/j.psep.2020.04.045>
- Shukla, R. G., Kumar, P. G., Kumar Vishwakarma, D. G., Ali, R., Kumar, R., & Kuriqi, A. (2021). Modeling of Stage-Discharge Using Back Propagation ANN, ANFIS, and WANN-based Computing Technique. <https://doi.org/10.21203/rs.3.rs-696059/v1>
- Sibiya, N. P., Amo-Duodu, G., Tetteh, E. K., & Rathilal, S. (2022). Model prediction of coagulation by magnetised rice starch for wastewater treatment using response surface methodology (RSM) with artificial neural network (ANN). *Scientific African*, 17. <https://doi.org/10.1016/j.sciaf.2022.e01282>.

- Siddique, N., & Adeli, H. (2013). Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing. John Wiley & Sons. 532p. <https://doi.org/978-1-118-33784-4>
- Simate, G. S. (2015). The treatment of brewery wastewater for reuse by integration of coagulation/flocculation and sedimentation with carbon nanotubes ‘sandwiched’ in a granular filter bed. *Journal of Industrial and Engineering Chemistry*, 21, 1277–1285. <https://doi.org/10.1016/j.jiec.2014.06.001>
- Simate, G. S., Cluett, J., Iyuke, S. E., Musapatika, E. T., Ndlovu, S., Walubita, L. F., & Alvarez, A. E. (2011). The treatment of brewery wastewater for reuse: State of the art. *Desalination*, 273(2–3), 235–247. <https://doi.org/10.1016/j.desal.2011.02.035>
- Siriwardhana, K. D., Jayaneththi, D. I., Herath, R. D., Makumbura, R. K., Jayasinghe, H., Gunathilake, M. B., Azamathulla, H. Md., Tota-Maharaj, K., & Rathnayake, U. (2023). A Simplified Equation for Calculating the Water Quality Index (WQI), Kalu River, Sri Lanka. *Sustainability*, 15(15), 12012. <https://doi.org/10.3390/su151512012>
- Soltani Mohamed. (2005). Distribution lipidique et voies métaboliques chez quatre bactéries gram-négatives hydrocarbonoclastes. Variation en fonction de la source de carbone. Université Paris 6.
- Some, Y. S. C., Soro, T. D., & Ouedraogo, S. (2014). Étude de la prévalence des maladies liées à l’eau et influences des facteurs environnementaux dans l’arrondissement de Nomgr-Masson: cas du quartier Tanghin (Ouagadougou-Burkina Faso). *International Journal of Biological and Chemical Sciences*, 8(1), 289–303. <https://doi.org/10.4314/ijbcs.v8i1.25>
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial neural networks in supply chain management, a review. *Journal of Economy and Technology*, 1, 179–196. DOI: <https://doi.org/10.1016/j.ject.2023.11.002>
- Soro, T. D., Fossou, N. M. R., Kone, G. Y. M., Oga, Y. M.-S., & Soro, N. (2022). Evaluation de la qualité des eaux souterraines du département de Grand-Lahou (Sud-Ouest de la Côte d’Ivoire) à partir de l’indice WQI. *International Journal of Innovation and Applied Studies*, 38(2), 417–427. <https://doi.org/2028-9324>
- Sorsa, T., & Koivo, H. N. (1993). Application of artificial neural networks in process fault diagnosis. *Automatica*, 29(4), 843–849. [https://doi.org/10.1016/0005-1098\(93\)90090-G](https://doi.org/10.1016/0005-1098(93)90090-G)

- Sou, M. Y., Mermoud, A., Yacouba, H., & Boivin, P. (2013). Impacts of irrigation with industrial treated wastewater on soil properties. *Geoderma*, 200, 31–39 p. <https://doi.org/10.1016/j.geoderma.2013.02.008>
- Sravani, D., Aruna Kumari, S., & Mruduladevi, K. (2023). Water quality Index Assessment of the Groundwater of Industrial area and absorption by Polymer Composites. *International Journal Of Research And Innovation In Social Science (IJRISS)*, Volume(V), 1114–1123. <https://doi.org/10.47772/IJRISS>
- Sridharan, A., & Jayadeva, M. S. (1980). Approximate potential-distance relationship for clays. *Soil Research*, 18(4), 461–466. <https://doi.org/10.1071/SR9800461>
- Stambuk-Giljanović N. (2003). Comparison of Dalmatian water evaluation indices. *Water Environment Research: A Research Publication of the Water Environment Federation*, 75(5), 388–405. <https://doi.org/10.2175/106143003X141196>
- Steinhart, C. E., Schierow, L.-J., & Chesters, G. (1981). An environmental quality index for the nearshore waters of the Great Lakes. Water Resources Center, University of Wisconsin-Madison. <https://doi.org/10.1111/j.1752-1688.1982.tb00110.x>
- Stoner, J. D., Andrus, C. D., & Menard, H. W. (1978). Water-Quality Indices for Specific Water Uses. United States, Department of the Interior Geological Survey. 140-770. DOI: <https://doi.org/10.12691/ajwr-7-2-4>
- Strande, L., Ronteltap, M., & Brdjanovic, D. (2018). *Gestion des Boues de Vidange: Approche intégrée pour la mise en œuvre et l'exploitation*. IWA Publishing. DOI: <https://doi.org/10.2166/9781780409801>
- Striebig, B., Ogundipe, A. A., Papadakis, M., & Heine, L. G. (2022). *Environmental Engineering and Sustainable Design 2e*. Chapter 1: Sustainability, Engineering, and Design. Cengage Learning. DOI: <https://doi.org/9780357675854>
- Sukandar, S., Yasuda, K., Tanaka, M., & Aoyama, I. (2006). Metals leachability from medical waste incinerator fly ash: a case study on particle size comparison. *Environmental Pollution*, 144(3), 726–735. <https://doi.org/10.1016/j.envpol.2006.02.010>
- Sunayana, Kalawapudi, K., Dube, O., & Sharma, R. (2020). Use of neural networks and spatial interpolation to predict groundwater quality. *Environment, Development and Sustainability*, 22(4), 2801–2816. <https://doi.org/10.1007/s10668-019-00319-2>

- Sundui, B., Ramirez Calderon, O. A., Abdeldayem, O. M., Lázaro-Gil, J., Rene, E. R., & Sambuu, U. (2021). Applications of machine learning algorithms for biological wastewater treatment: Updates and perspectives. *Clean Technologies and Environmental Policy*, 23(1), 127–143. <https://doi.org/10.1007/s10098-020-01993-x>
- Sutadian, A. D., Muttill, N., Yilmaz, A. G., & Perera, B. J. C. (2018). Development of a water quality index for rivers in West Java Province, Indonesia. *Ecological Indicators*, 85, 966–982. <https://doi.org/10.1016/J.ECOLIND.2017.11.049>
- Sy, I., Traoré, D., Niang Diène, A., Koné, B., Lô, B., Faye, O., Utzinger, J., Cissé, G., & Tanner, M. (2017). Eau potable, assainissement et risque de maladies diarrhéiques dans la Communauté Urbaine de Nouakchott, Mauritanie. *Santé Publique*, 29(5), 741–750. <https://doi.org/10.3917/spub.175.0741>
- Tampo, L., Kaboré, I., Alhassan, E. H., Ouéda, A., Bawa, L. M., & Djaneye-Boundjou, G. (2021). Benthic Macroinvertebrates as Ecological Indicators: Their Sensitivity to the Water Quality and Human Disturbances in a Tropical River. *Frontiers in Water*, 3. <https://doi.org/10.3389/frwa.2021.662765>
- Tchobanoglous, G., Stensel, H. D., Tsuchihashi, R., Burton, F., Abu-Orf, M., Bowden, G., & Pfrang, W. (2014). *Wastewater engineering: treatment and resources recovery*. Metcalf and Eddy Inc. p 2018. <https://9781259250934>
- Tchobanoglous, G., Burton, F., & Stensel, H. D. (2003). *Wastewater engineering: treatment and reuse*. American Water Works Association. Journal, 95(5), 201. <https://007-041878-0>
- Templeton, M. R., & Butler, D. (2011). *Introduction to wastewater treatment*. Bookboon. <https://978-87-7681-843-2>
- Thamcharoen, T., Srisertpol, J., Chommuangpuck, P., & Deeying, J. (2020). Fault Detection and Classification for Slider Attachment Process using Convolution Neural Network. *International Journal of Neural Networks and Advanced Applications*, 7, 60–65. <https://doi.org/10.46300/91016.2020.7.9>
- Thomas, O., & Mazas, N. (1986). La mesure de la demande chimique en oxygène dans les milieux faiblement pollués. *Analisis*, 14(6), 300–302. <https://www.researchgate.net/publication/284773037>

- Tibebe, D., Kassa, Y., Melaku, A., & Lakew, S. (2019). Investigation of spatio-temporal variations of selected water quality parameters and trophic status of Lake Tana for sustainable management, Ethiopia. *Microchemical Journal*, 148, 374–384. <https://doi.org/10.1016/J.MICROC.2019.04.085>
- Tiyasha, Tung, T. M., & Yaseen, Z. M. (2020). A survey on river water quality modelling using artificial intelligence models: 2000–2020. *Journal of Hydrology*, 585, 124670. <https://doi.org/10.1016/J.JHYDROL.2020.124670>
- Touzet, C. (1992). Les réseaux de neurones artificiels, introduction au connexionnisme. Ec2.
- Trach, R., Trach, Y., Kiersnowska, A., Markiewicz, A., Lendo-Siwicka, M., & Rusakov, K. (2022). A Study of Assessment and Prediction of Water Quality Index Using Fuzzy Logic and ANN Models. *Sustainability (Switzerland)*, 14(9). <https://doi.org/10.3390/su14095656>
- Tran, A. T. K., Zhang, Y., Jullok, N., Meesschaert, B., Pinoy, L., & Van der Bruggen, B. (2012). RO concentrate treatment by a hybrid system consisting of a pellet reactor and electro dialysis. *Chemical Engineering Science*, 79, 228–238. <https://doi.org/10.1016/J.CES.2012.06.001>.
- Tripathi, M., & Singal, S. K. (2019). Use of Principal Component Analysis for parameter selection for development of a novel Water Quality Index: A case study of river Ganga India. *Ecological Indicators*, 96, 430–436. <https://doi.org/https://doi.org/10.1016/j.ecolind.2018.09.025>.
- Uddin, M. G., Moniruzzaman, M., Quader, M. A., & Hasan, M. A. (2018). Spatial variability in the distribution of trace metals in groundwater around the Rooppur nuclear power plant in Ishwardi, Bangladesh. *Groundwater for Sustainable Development*, 7, 220–231. <https://doi.org/10.1016/J.GSD.2018.06.002>
- Uddin, M. G., Nash, S., & Olbert, A. I. (2021). A review of water quality index models and their use for assessing surface water quality. *Ecological Indicators*, 122, 107218. <https://doi.org/10.1016/J.ECOLIND.2020.107218>
- Uddin, M. G., Nash, S., Rahman, A., & Olbert, A. I. (2022). A comprehensive method for improvement of water quality index (WQI) models for coastal water quality assessment. *Water Research*, 219, 118532. <https://doi.org/10.1016/J.WATRES.2022.118532>

- Udeshani, W. A. C., Dissanayake, H. M. K. P., Gunatilake, S. K., & Chandrajith, R. (2020). Assessment of groundwater quality using water quality index (WQI): A case study of a hard rock terrain in Sri Lanka. *Groundwater for Sustainable Development*, 11. <https://doi.org/10.1016/j.gsd.2020.100421>
- Vandecasteele, J.-P., & Ourisson, G. (2005). *Microbiologie pétrolière : concepts, implications environnementales, applications industrielles*. Editions Technip. <https://doi.org/2-7108-0827-7>
- Vera, M., Aspé, E., Marti, M. C., & Roeckel, M. (1999). Optimization of a sequential anaerobic-aerobic treatment of a saline fishing effluent. *Process Safety and Environmental Protection*, 77(5), 275–290. <https://doi.org/10.1205/095758299530152>
- Verma, A. K., Dash, R. R., & Bhunia, P. (2012). A review on chemical coagulation/flocculation technologies for removal of colour from textile wastewaters. *Journal of Environmental Management*, 93(1), 154–168. <https://doi.org/10.1016/j.jenvman.2011.09.012>
- Vijayaraghavan, K., Ahmad, D., & Lesa, R. (2006). Electrolytic treatment of beer brewery wastewater. *Industrial & Engineering Chemistry Research*, 45(20), 6854–6859. <https://doi.org/10.1021/ie0604371>
- Vilaginès, R., & Vilaginès, R. (2000). *Eau, environnement et santé publique : introduction à l'hydrologie*. Technique et documentation. <https://9782743004200>
- Villebrun, J. F. (1989). *La déphosphatation biologique appliquée à la station d'épuration de Craon, Rapport de la DDAF de la Mayenne*. Volume.
- Villeneuve, V., Légaré, S., Painchaud, J., & Vincent, W. (2006). Dynamique et modélisation de l'oxygène dissous en rivière. *Revue Des Sciences de l'eau*, 19(4), 259–274. <https://doi.org/10.7202/014414ar>
- Volkman, J. K., Holdsworth, D. G., Neill, G. P., & Bavor, H. J. (1992). Identification of natural, anthropogenic and petroleum hydrocarbons in aquatic sediments. *Science of The Total Environment*, 112(2–3), 203–219. [https://doi.org/10.1016/0048-9697\(92\)90188-X](https://doi.org/10.1016/0048-9697(92)90188-X)
- Von Sperling, M. (2007). *Wastewater characteristics, treatment and disposal*. IWA publishing. <https://doi.org/10.2166/9781780402086>

- Wang, K., Mao, Y., Wang, C., Ke, Q., Zhao, M., & Wang, Q. (2022). Application of a combined response surface methodology (RSM)-artificial neural network (ANN) for multiple target optimization and prediction in a magnetic coagulation process for secondary effluent from municipal wastewater treatment plants. *Environmental Science and Pollution Research*, 29, 1–13. <https://doi.org/10.1007/s11356-021-18060-7>
- Wen, C. H., & Vassiliadis, C. A. (1998). Applying hybrid artificial intelligence techniques in wastewater treatment. *Engineering Applications of Artificial Intelligence*, 11(6), 685–705. [https://doi.org/10.1016/S0952-1976\(98\)00036-0](https://doi.org/10.1016/S0952-1976(98)00036-0)
- Werbos, P. J. (2005). Applications of advances in nonlinear sensitivity analysis. *System Modeling and Optimization: Proceedings of the 10th IFIP Conference New York City, USA, August 31–September 4, 1981*, 762–770. <https://978-3-540-11691-2>
- Widrow, B., & Hoff, M. E. (1960). Adaptive switching circuits. *IRE WESCON Convention Record*, 4(1), 96–104. <https://doi.org/2379772>
- Willmott, C. J. (1981). On the validation of models. *Physical Geography*, 2(2), 184–194. <https://doi.org/10.1080/02723646.1981.10642213>
- Xia, L., Han, Q., Shang, L., Wang, Y., Li, X., Zhang, J., Yang, T., Liu, J., & Liu, L. (2022). Quality assessment and prediction of municipal drinking water using water quality index and artificial neural network: A case study of Wuhan, central China, from 2013 to 2019. *Science of The Total Environment*, 844, 157096. <https://doi.org/10.1016/J.SCITOTENV.2022.157096>
- Xin, C., Shi, X., Wang, D., Yang, C., Li, Q., & Liu, H. (2020). Multi-grained cascade forest for effluent quality prediction of papermaking wastewater treatment processes. *Water Science and Technology*, 81. <https://doi.org/10.2166/wst.2020.206>
- Xu, T. (2015). Valorisation et décontamination des métaux présents dans les poussières de four à arc électrique (EAF) issues de la fabrication de l'acier. Mémoire. Québec, Université du Québec, Institut national de la recherche scientifique, Maîtrise en sciences de la terre, 242 p.
- YANG, H. jun, SHEN, Z. min, ZHANG, J. ping, & WANG, W. hua. (2007). Water quality characteristics along the course of the Huangpu River (China). *Journal of Environmental Sciences*, 19(10), 1193–1198. [https://doi.org/10.1016/S1001-0742\(07\)60195-8](https://doi.org/10.1016/S1001-0742(07)60195-8)

- Ye, Z., Yang, J., Zhong, N., Tu, X., Jia, J., & Wang, J. (2020). Tackling environmental challenges in pollution controls using artificial intelligence: A review. *Science of the Total Environment*, 699, 134279. <https://doi.org/10.1016/j.scitotenv.2019.134279>
- Yoo, C., Hwang, S.-J., & Moon, I. (2008). Hybrid Fuzzy Modeling of Wastewater Quality with Artificial Intelligence Learning. *Environmental Engineering Science - ENVIRON ENG SCI*, 25, 941–950. <https://doi.org/10.1089/ees.2007.0100>
- Zaghloul, G. Y., Zaghloul, A. Y., Hamed, M. A., El-Moselhy, K. M., & El-Din, H. M. E. (2023). Water quality assessment for Northern Egyptian lakes (Bardawil, Manzala, and Burullus) using NSF-WQI Index. *Regional Studies in Marine Science*, 64, 103010. <https://doi.org/10.1016/J.RSMA.2023.103010>
- Zahrim, A. Y., Tizaoui, C., & Hilal, N. (2011). Coagulation with polymers for nanofiltration pre-treatment of highly concentrated dyes: a review. *Desalination*, 266(1–3), 1–16. <https://doi.org/10.1016/j.desal.2010.08.012>
- Zaviska, F., Drogui, P., Mercier, G., & Blais, J.-F. (2009). Procédés d'oxydation avancée dans le traitement des eaux et des effluents industriels : Application à la dégradation des polluants réfractaires. *Revue Des Sciences de l'eau*, 22(4), 535–564. <https://doi.org/10.7202/038330ar>
- Zhang, F., Chan, N. W., Liu, C., Wang, X., Shi, J., Kung, H. Te, Li, X., Guo, T., Wang, W., & Cao, N. (2021). Water quality index (Wqi) as a potential proxy for remote sensing evaluation of water quality in arid areas. *Water (Switzerland)*, 13(22). <https://doi.org/10.3390/w13223250>.
- Zhang, Z., Zhang, W., Hu, X., Li, K., Luo, P., Li, X., Xu, W., Li, S., & Duan, C. (2020). Evaluating the efficacy of point-of-use water treatment systems using the water quality index in rural Southwest China. *Water (Switzerland)*, 12(3). <https://doi.org/10.3390/w12030867>.
- Zhou, M., Liu, L., Jiao, Y., Wang, Q., & Tan, Q. (2011). Treatment of high-salinity reverse osmosis concentrate by electrochemical oxidation on BDD and DSA electrodes. *Desalination*, 277(1–3), 201–206. <https://doi.org/10.1016/J.DESAL.2011.04.030>.