

Université Mohamed Boudiaf - M'sila

FACULTE DE TECHNOLOGIE
DEPARTEMENT GENIE ELECTRIQUE



Numéro de série :

Numéro d'inscription D.AUT/3C/01/17

Thèse

Présentée pour l'obtention du diplôme de

DOCTORAT TROISIEME CYCLE

Filière : Génie électrique

Spécialité : Automatique

THEME

Contribution à la surveillance et le diagnostic des systèmes de production intelligents en Algérie

Présenté par

KHELIL Mohamed Imed

Soutenu le : **16/03/2023** devant le jury composé de :

ZEGHLACHE Samir	Professeur – Université de M'sila	Président
LADJAL Mohamed	Professeur – Université de M'sila	Rapporteur
NEMRA Abdelkrim	M.C.A – Ecole Militaire Polytechnique - Bordj El Bahri- Alger	Examineur
HACINE-GHARBI Abdenour	M.C.A – Université de BBA	Examineur
DJERIOUI Ali	M.C.A – Université de M'sila	Examineur
GHELLAB Mohamed Zinelaabidine	M.C.A – Université de M'sila	Examineur
OUALI Mohammed Assam	M.C.A – Université de M'sila	Invité

Année Universitaire : 2022/2023

REMERCIEMENTS

Je tiens à remercier premièrement mon rapporteur Monsieur **Prof. LADJAL Mohamed**, Professeur à l'université de M'sila pour avoir accepté de m'encadrer et de me suivre tout au long de la réalisation de cette thèse, pour sa grande patience dont il a su faire preuve malgré ses charges académiques et professionnelles. Je pourrai cordialement lui exprimé mes profonds remerciements pour son soutien et sa présence dans les moments les plus pénibles. Qu'il trouve ici l'expression de ma gratitude pour la confiance qu'il m'a faite.

Je remercie Monsieur **Prof. ZEGHLACHE Samir**, Professeur à l'université de M'sila pour l'honneur qu'il me fait en présidant ce jury, et par son esprit scientifique de haut niveau, pour m'avoir orienté vers le plus approprié.

J'adresse également mes très sincères remerciements à l'ensemble des membres pour l'honneur qu'ils m'ont fait pour avoir accepté de faire partie de ce jury en acceptant d'examiner et d'évaluer cette thèse. J'exprime mes vifs respects au **Dr. NEMRA Abdelkrim**, Maître de conférences (A) à l'Ecole Militaire Polytechnique (EMP) - Bordj El Bahri- Alger, au **Dr. HACINE-GHARBI Abdenour**, Maître de conférences (A) à l'université de BBA, au **Dr. DJERIOUI Ali**, Maître de conférences (A) à l'université de M'sila, au **Dr. GHELLAB Mohamed Zinelaabidine**, Maître de conférences (A) à l'université de M'sila et au **Dr. OUALI Mohammed Assam**, Maître de conférences (A) à l'université de M'sila. Soyez assurés messieurs les membres du jury de ma profonde reconnaissance pour l'attention que vous avez portée à cette thèse et pour le temps que vous avez consacré à son évaluation.

Je tiens à remercier les ingénieurs de la direction du barrage de Tilesdit (Bouira) et du barrage de Cheliff (Mostaganem) pour leurs soutiens et pour avoir fourni les informations nécessaires pour l'élaboration de ce travail et l'accès aux bases de données.

A mes chers parents et tous mes frères,

A mon meilleure amie Wafa,

A mes amis

Merci d'être toujours là pour moi.

Table des matières

RESUME.....	vii
ABREVIATIONS ET NOTATIONS.....	viii
LISTE DES FIGURES.....	xii
LISTE DES TABLEAUX.....	xv
INTRODUCTION GENERALE.....	01

CHAPITRE I

SURVEILLANCE INDUSTRIELLE INTELLIGENTE ET TRAITEMENT D'EAU

Introduction.....	07
1.1. Maintenance et Surveillance Industrielle	08
1.1.1. La maintenance	08
1.2. Surveillance industrielle : Définitions, Intérêt et Enjeux.....	09
1.2.1. Définitions.....	09
1.2.2. Vers un système de surveillance intelligent.....	14
1.3. Méthodes de Surveillance et intelligence artificielle.....	16
1.3.1. Méthode de surveillance à base de modèle.....	18
1.3.2. Méthode de surveillance sans modèle	19
1.4. Les étapes de traitement et production des eaux potables	21
1.4.1. Prétraitement.....	22
1.4.2. Pré-oxydation.....	22

1.4.3.	Clarification	22
1.4.4.	Désinfection.....	24
1.4.5.	Affinage.....	25
1.5.	Surveillance de la qualité de l'eau par reconnaissance de formes.....	26
	Conclusion.....	29

CHAPITRE II

ANALYSE DE DONNEES

Introduction.....		30
2.1. Etat de l'art		31
2.1.1. Méthodes géométriques.....		32
2.2. Méthodes de sélection des caractéristiques et de classification automatique.....		34
2.2.1. Analyse en composantes principales (ACP).....		35
2.2.2. Carte auto-organisatrice (self-organizing map SOM).....		43
2.2.3. Classification hiérarchique ascendante ou clustering hiérarchique.....		56
Conclusion.....		60

CHAPITRE III

TECHNIQUES DE CLASSIFICATION

ET REGRESSION

Introduction.....		61
3.1. Réseaux de neurone artificiels.....		62
3.1.1. Définitions.....		62
3.1.2. Historique.....		63

3.1.3.	Intérêts pour l'utilisation des RNA.....	64
3.1.4.	Concept neurobiologique	65
3.1.5.	Les modèles mathématiques.....	66
3.1.6.	Structure de neurone artificiel.....	67
3.1.7.	Comportement.....	67
3.1.8.	Fonctions d'activation.....	68
3.1.9.	Architectures d'un réseau de neurones.....	69
3.1.10.	Apprentissage.....	70
3.1.11.	Modèles des réseaux de neurones artificiels.....	72
3.2.	Les machines à vecteurs de support.....	79
3.2.1.	Théorie de Vapnik-Chervonenkis.....	79
3.2.2.	Risque structurel.....	82
3.2.3.	Principe des SVMs.....	83
3.3.	Les réseaux récurrents à mémoire court et long terme.....	89
3.3.1.	Présentation des LSTMs	89
3.3.2.	Architecture d'une unité LSTM.....	90
3.3.3.	Fonctionnement d'une unité LSTM.....	93
	Conclusion.....	97

CHAPITRE IV

SIMULATION ET EVALUATION

Introduction.....	99
4.1. Problématique de la surveillance et de diagnostic et les travaux connexes	100
4.1.1. Rôle de chaque bloc.....	101
4.2. Zones d'étude et données d'entrée.....	104

4.2.1.	Le barrage de Tilesdit.....	104
4.2.2.	Le barrage de Cheliff.....	105
4.3.	Approche utilisée dans la surveillance et diagnostic.....	107
4.4.	Résultats et discussion.....	108
4.4.1.	Sélection des caractéristiques.....	109
4.4.2.	Application à la classification de la qualité de l'eau.....	116
4.4.3.	Détection des anomalies, Validation et reconstruction des données manquantes.....	123
4.4.4.	Prédiction de la dose du coagulant, l'indice de qualité de l'eau et capteurs logiciels.....	136
	Conclusion.....	146
	Conclusion générale.....	147
	Références	

RESUME

L'objectif des travaux de développement des outils de surveillance/diagnostic d'un système de production d'eau dans son ensemble est la maîtrise de la qualité de l'eau et la diminution des contraintes de coût de fonctionnement, objet d'une réglementation très stricte des pouvoirs publics. L'établissement de modèles du comportement des systèmes est un problème incontournable en automatique. D'importants efforts dans le développement de méthodes de contrôle, de diagnostic et de surveillance automatique ont été effectués durant ces dernières années. Le présent travail s'inscrit dans ce courant de recherche, en proposant une nouvelle approche de la surveillance et de diagnostic de systèmes de production d'eau propre en fonction des caractéristiques intrinsèques à l'aide d'un modèle basé sur les techniques avancées d'intelligence artificielle. La préparation de la base de données dans ce type d'application consiste à retenir les variables les plus représentatives des données observées. Elle peut être utile comme étape préliminaire à tout processus d'analyse et de classification ou régression afin de se concentrer sur les variables les plus importantes et réduire le coût d'exécution d'un tel processus.

L'objectif recherché dans ce travail, est une contribution à l'étude, à la conception, et au développement de nouveaux systèmes intelligents de contrôle, de diagnostic et de surveillance de la qualité de l'eau propre par reconnaissance de formes. Il consiste à la recherche d'une validation et évaluation complète exprimant les variables indicatrices de système de production choisi pour l'aide à la décision. Cette décision est basée sur l'application des techniques de l'intelligence artificielle de deux zones d'étude en Algérie. L'intérêt principal du système réside dans sa capacité à prendre en compte diverses sources d'incertitude, telles que des données d'entrées atypiques, des erreurs de mesure et la taille limitée de l'ensemble d'apprentissage. Des résultats expérimentaux sont présentés et montrent l'efficacité de cette approche. Plusieurs exemples d'application sont prévus à cet effet : la sélection des caractéristiques, le développement des capteurs logiciels vu comme un problème de régression, et le contrôle de potabilité de l'eau et la détection des anomalies et la reconstruction des données manquantes ou invalides en tant que problème de classification.

Mots clés : Qualité de l'eau, Surveillance, Diagnostic, SOM, ACP, CAH, Sélection des caractéristiques, Classification, Régression, RNA, SVM, LSTM, Capteurs logiciels, Coagulation, Indice de qualité, Algérie.

ABREVIATIONS ET NOTATIONS

NTIC : Nouvelles Technologies de l'Information et de la Communication

IA : Intelligence Artificielle

AMDEC : Analyse des Modes de Défaillance, de leurs Effets et de leurs Criticité

ADD : Arbres De Défaillances

INRIA : Interprétation Prédicative d'Association

IRISA: Approche Recognition Operational Model Failure Model

BPN: Behavioral Petri Nets

PMC : Multi-Layer Perceptron (Multi-Layers Perceptron)

THM : Trihalométhanes

pH : potentiel Hydrogène

C : concentration

T : temps de contact

HClO : Acide hypochloreux

ClO : l'ion hypochlorite

UV : ultraviolet

ADN : Anime Digital Network

NH₄⁺: Ammonium

NO₂⁻ : Nitrite

CaCO₃: carbonate de calcium

CO₂ : dioxyde de carbone

ACP : Analyse du composant principal

SOM: Self organizing-map

PC: composante principale

BMU: Best Matching Unit

NN: Neural Network

QE : Erreur de Quantification

TE : Erreur Topographique

EEG: Electroencéphalographie

RBF: Radial Basis Function network

ANN : Artificial Neural Network

Tanh : tangente hyperbolique
RNN : réseaux de neurones récurrents
DBN : Deep Belief Network
RNP : Réseaux de Neurones Profonds
SVM : machines à vecteurs de support
VC : Vapnik Chervonenkis
SRM : minimisation des risques structurels
KKT : Karush-Kuhn-Tucker
SMO : Optimisation minimale et séquentielle
QP: Quadratic Programming
OAO: one against one
OAA: one against all
LSTM: Long Short-Term Memory
CEC : Constant Error Carousel
CA : analyse en grappes
O.M.S : Organisation Mondiale de la Santé
T° : Température
C : Conductivité
TUR : Turbidité
DO : Oxygène Dissous
Mg²⁺ : magnésium
TH : Dureté Totale
PEH : Dureté Permanente
TDS : Solides Dissous Totaux
EC : Conductivité Electrique
TP: True Positive
TN: True Negative
FP : False Positives
FN : False Negatives

LISTE DES FIGURES

Fig. 1.1. Composantes de la surveillance industrielle.	11
Fig. 1.2. Architecture générale d'un système de supervision en ligne.	12
Fig. 1.3. Les outils de surveillance, de diagnostic et d'aide à la décision au niveau de la supervision	12
Fig. 1.4. Surveillance classique et surveillance dynamique	13
Fig. 1.5. Exemple d'une boucle de supervision (surveillance + action)	15
Fig.1.6. Classification globale des méthodes de surveillance et de diagnostic	18
Fig. 1.7. Les outils d'IA sont classés en fonction de la méthode de diagnostic	20
Fig. 1.8. Chaîne de traitement et de production d'eau potable	21
Fig. 1.9. Coagulation-Floculation	23
Fig.1.10. Schéma général du système de surveillance de l'eau par reconnaissance de formes	27
Fig. 2.1. Méthodes de classification non supervisée	32
Fig. 2.2. Grilles et voisinages de neurones les plus courants.	44
Fig. 2.3, (a). Réseau SOM 1D, (b). Réseau SOM 2D.	44
Fig. 2.4. Cartes auto-organisatrices pour la classification en deux étapes	45
Fig. 2.5. Fonction de voisinage gaussienne	47
Fig. 2.6. Fonction de chapeau mexicain	47
Fig. 2.7. La représentation de la matrice en U avec des hexagones blancs dimensionnés proportionnellement au nombre d'échantillons tombant sur chaque nœud.	51
Fig. 2.8. Illustration du mécanisme de validation des données 3D.	54
Fig. 2.9. Illustration du mécanisme d'estimation des données manquantes 2D.	56
Fig. 2.10. Clustering hiérarchique	57

Fig. 3.1. Structure d'un neurone biologique	66
Fig. 3.2, (a). Potentiel d'action. (b) Opération au niveau synaptique (a) L'arrivée d'un potentiel d'action. (b) Libération de neuromédiateurs dans l'espace synaptique.	66
Fig. 3.3. Faites correspondre les neurones biologiques/neurones artificiels	67
Fig. 3.4. Les fonctions les plus utilisées adaptées en ingénierie	68
Fig. 3.5. Architecture d'un réseau de neurones	70
Fig. 3.6. Schéma d'un Perceptron Simple	73
Fig. 3.7. Schéma de principe d'un PMC	74
Fig. 3.8. Une représentation compacte d'un RNN. Toutes les flèches représentent des connexions complètes. Les flèches en pointillé indiquent les connexions avec un décalage dans le temps ($t - 1$)	76
Fig. 3.9. Une représentation élargie d'un RNN.	77
Fig. 3.10. Importance du choix de l'ensemble ϕ dans lequel est sélectionnée la fonction de décision.	80
Fig. 3.11. Une illustration de l'inégalité structurelle des risques. La courbe croissante, appelée la confiance, correspond à une borne supérieure sur le terme de complexité	81
Fig. 3.12. Les flèches indiquent le côté de la ligne où les points seront classés positivement	82
Fig. 3.13. Structures imbriquées d'une classe de fonctions	82
Fig. 3.14. Hyperplan de séparation linéaire pour les données séparables linéairement. (Les vecteurs de support sont encerclés).	84
Fig. 3.15. Hyperplan de séparation linéaire pour les données non linéairement séparables.	87
Fig. 3.16. Illustration de l'effet de changement d'espace (mapping) par une fonction noyau.	87
Fig. 3.17. Une chaîne de cellules LSTM.	89
Fig. 3.18. Un réseau avec des cellules LSTM est représenté dans la couche cachée. Image reproduite avec l'aimable autorisation de Lapalme	91
Fig. 3.19. Une cellule LSTM équipée d'un bloc est représentée, elle-même équipée d'une cellule. Image extraite de Gers et al	92
Fig. 3.20. Schéma de principe des étapes de propagation vers l'avant dans un RNN-LSTM pour l'ensemble de la séquence. Chaque symbole de la séquence est représenté par une couleur. Les symboles de couleur plus claire représentent des versions codées des symboles présentés en entrée du réseau.	95
Fig. 4.1. Le système multi-capteurs de surveillance de la qualité de l'eau	102
Fig. 4.2. Carte géographique et image montrant la région étudiée : Barrage du Tilesdit – Bouira – Algérie [Google Maps].	104

Fig. 4.3. Carte géographique et image montrant la région étudiée : Barrage du Cheliff – Mostaganem – Algérie [Google Maps].	106
Fig. 4.4. Le cadre proposé pour la surveillance de la qualité de l'eau.	108
Fig. 4.5. Partie évolution des variables de qualité de l'eau – Barrage Tilesdit.	110
Fig. 4.6. Visualisation des plans variables (CP) et de la matrice U pour les données d'entrée affichées sur SOM – Barrage Tilesdit.	111
Fig. 4.7. Visualisation des plans variables sélectionnés par SOM– Barrage Tilesdit	112
Fig. 4.8. Visualisation des plans variables (CP) et de la matrice U pour les données d'entrée affichées sur SOM – Barrage Cheliff.	113
Fig. 4.9. Caractéristiques de l'eau brute – Barrage Tilesdit.	124
Fig. 4.10. Caractéristiques de l'eau brute (Cheliff)	125
Fig. 4.11, (a). Plans composants du SOM pour un fonctionnement normal (Tilesdit)	125
Fig. 4.11, (b). Plans composants du SOM pour un fonctionnement normal (Cheliff)	125
Fig. 4.12, (a). Dendrogramme CAH, fonctionnement normal (4 capteurs) – Barrage Tilesdit	126
Fig. 4.12, (b). Dendrogramme CAH : fonctionnement normal (4 capteurs) – Barrage Cheliff.	126
Fig. 4.13, (a). Mesure du pH avec défaut artificiel- Barrage Tilesdit	127
Fig. 4.13, (b). Mesure de Conductivité avec défaut artificiel- Barrage Tilesdit	127
Fig. 4.14, (a). Mesure du pH avec défaut artificiel- Barrage Cheliff	128
Fig. 4.14, (b). Mesure de conductivité avec défaut artificiel - Barrage Cheliff	128
Fig. 4.15, (a). détection de défaut du capteur pH-Barrage Tilesdit	128
Fig. 4.16, (a). détection de défaut du capteur Conductivité-Barrage Tilesdit.	128
Fig. 4.15, (b). détection de défaut du capteur pH – Barrage Cheliff	129
Fig. 4.16, (b). détection de défaut du capteur Conductivité-Barrage Cheliff.	129
Fig. 4.17, (a). Plans des composants du SOM montrant le défaut du capteur pH-Barrage Tilesdit.	129
Fig. 4.17, (b). Plans des composants du SOM montrant le défaut du capteur pH - Barrage Cheliff.	129
Fig. 4.18, (a). Plans des composants du SOM indiquant le défaut du capteur de conductivité - Barrage Tilesdit	130
Fig. 4.18, (b) Plans des composants du SOM indiquant le défaut du capteur de conductivité - Barrage Cheliff.	130
Fig. 4.19, (a). Plans des composants du SFOM montrant le défaut des capteurs de conductivité et de pH- Barrage Tilesdit.	130

Fig. 4.19, (b). Plans des composants du SFOM montrant le défaut des capteurs de conductivité et de pH-Barrage Cheliff.	130
Fig. 4.20, (a). Détection de défaut du capteur de conductivité et de pH-Barrage Tilesdit.	131
Fig. 4.20, (b). Détection de défaut des capteurs de conductivité et de pH-Barrage Cheliff.	131
Fig. 4.21, (a). Mesure du pH avec un défaut artificiel- Barrage Tilesdit	132
Fig. 4.21, (b). Mesure de la conductivité avec un défaut artificiel- Barrage Tilesdit.	132
Fig. 4.22, (a et b). Reconstruction du pH défectueuse-Barrage Tilesdit	132
Fig. 4.23, (a et b). Reconstruction de conductivité défectueuse-Barrage Tilesdit	133
Fig. 4.24, (a). Mesure du pH avec un défaut artificiel- Barrage Cheliff	134
Fig. 4.24, (b). Mesure de conductivité avec un défaut artificiel- Barrage Cheliff	134
Fig. 4.25, (a et b) Reconstruction du pH défectueuse-Barrage Cheliff	134
Fig. 4.26, (a et b) Reconstruction de conductivité défectueuse-Barrage Cheliff	134
Fig. 4.27. Comparaison entre les valeurs réelles mesurées et prédites de dose optimale de coagulant de l'ensemble de données d'apprentissage.	137
Fig. 4.28. Comparaison entre les valeurs réelles mesurées et prédites de dose optimale de coagulant de l'ensemble de données de test.	138
Fig. 4.29. Modèle de prédiction de l'indice IQE par RNA.	144
Fig. 4.30. Résultats d'apprentissage de l'IQE par le modèle RNA.	144
Fig. 4.31. Résultats de test de l'IQE par le modèle RNA.	145

LISTE DES TABLEAUX

Tableau. 2.1. Caractéristiques associées au clustering hiérarchique	58
Tableau. 2.2. Comparaison entre les méthodes d'analyses de données utilisées.	59
Tableau. 3.1. Fonctions de transfert $a = f(n)$.	68
Tableau. 3.2. Exemple de différents types d'apprentissages en mode supervisé.	71
Tableau. 3.3. Exemple de différents types d'apprentissages en mode non supervisé.	72
Tableau. 3.4. Comparaison entre les méthodes de classification et de régression utilisées.	96
Tableau. 4.1. Mesures descriptives des paramètres de qualité de l'eau utilisée-Tilesdit	105
Tableau. 4.2. Mesures descriptives des paramètres de qualité de l'eau utilisée – Cheliff	106
Tableau 4.3. Statistiques descriptives des principaux composants créés.	115
Tableau. 4.4. Les résultats du modèle de classification LSTM dans les phases de formation et de test.	119
Tableau. 4.5. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de formation.	120
Tableau. 4.6. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de test.	121
Tableau. 4.7. Comparaison entre les méthodes proposées et les méthodes de classification rapportées antérieurement dans différents bases de données.	122
Tableau. 4.8. Classification décision pour un fonctionnement normal – Méthode CAH.	126
Tableau. 4.9. Valeurs du pH réelles, prévues et aberrantes du barrage de Tilesdit	134
Tableau. 4.10. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Tilesdit.	135
Tableau. 4.11. Valeurs du pH réelles, prévues et aberrantes du barrage de Cheliff.	135
Tableau. 4.12. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Cheliff.	135

Tableau. 4.13. Mesures de performance des résultats de la reconstruction des données pour les deux barrages.	135
Tableau. 4.14. Mesures de performance du modèle SVR de capteur logiciel de la dose optimal de coagulant.	138
Tableau. 4. 15. Base de données sur les normes d'eau brute 2009 et 2011 – Barrage Tilesdit	139
Tableau. 4.16. Classification et usage possible de l'eau selon l'IQE	141
Tableau. 4.17. Valeur des paramètres physiques et chimiques et normes algériennes de qualité des eaux de surface année 2018.	142
Tableau. 4. 18. Valeurs de l'indice IQE et classe de qualité des eaux de surface pour le barrage de Tilesdit dans l'année 2018	143

LISTE DES TABLEAUX

Tableau. 2.1. Caractéristiques associées au clustering hiérarchique	58
Tableau. 2.2. Comparaison entre les méthodes d'analyses de données utilisées.	59
Tableau. 3.1. Fonctions de transfert $a = f(n)$.	68
Tableau. 3.2. Exemple de différents types d'apprentissages en mode supervisé.	71
Tableau. 3.3. Exemple de différents types d'apprentissages en mode non supervisé.	72
Tableau. 3.4. Comparaison entre les méthodes de classification et de régression utilisées.	96
Tableau. 4.1. Mesures descriptives des paramètres de qualité de l'eau utilisée-Tilesdit	105
Tableau. 4.2. Mesures descriptives des paramètres de qualité de l'eau utilisée – Cheliff	106
Tableau 4.3. Statistiques descriptives des principaux composants créés.	115
Tableau. 4.4. Les résultats du modèle de classification LSTM dans les phases de formation et de test.	119
Tableau. 4.5. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de formation.	120
Tableau. 4.6. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de test.	121
Tableau. 4.7. Comparaison entre les méthodes proposées et les méthodes de classification rapportées antérieurement dans différents bases de données.	122
Tableau. 4.8. Classification décision pour un fonctionnement normal – Méthode CAH.	126
Tableau. 4.9. Valeurs du pH réelles, prévues et aberrantes du barrage de Tilesdit	134
Tableau. 4.10. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Tilesdit.	135
Tableau. 4.11. Valeurs du pH réelles, prévues et aberrantes du barrage de Cheliff.	135
Tableau. 4.12. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Cheliff.	135

Tableau. 4.13. Mesures de performance des résultats de la reconstruction des données pour les deux barrages.	135
Tableau. 4.14. Mesures de performance du modèle SVR de capteur logiciel de la dose optimal de coagulant.	138
Tableau. 4. 15. Base de données sur les normes d'eau brute 2009 et 2011 – Barrage Tilesdit	139
Tableau. 4.16. Classification et usage possible de l'eau selon l'IQE	141
Tableau. 4.17. Valeur des paramètres physiques et chimiques et normes algériennes de qualité des eaux de surface année 2018.	142
Tableau. 4. 18. Valeurs de l'indice IQE et classe de qualité des eaux de surface pour le barrage de Tilesdit dans l'année 2018	143

INTRODUCTION GENERALE

Toutes les eaux de la nature ne sont pas bonnes à boire. L'eau est ainsi le vecteur de transmission privilégié de nombreuses maladies [8]. La dégradation de la qualité de l'eau potable influe sur la santé publique à travers d'effets directs et indirects. Tout cela oblige de trouver les solutions nécessaires pour rendre l'eau de diverses sources, en particulier des eaux de surface en une bonne qualité. La quantité d'eau à la surface de la terre est constante, cependant 97.23% de celle-ci est en réalité salée et impropre à une consommation directe [1, 2, 3]. Il faut insister sur le fait que le problème de l'eau n'est pas un problème de quantité, mais un problème de flux [1, 4, 5]. Un manque de protection de ces masses d'eau contre les multiples contaminants peut entraîner une dégradation de l'état qualitatif de l'eau pour la consommation humaine. Pour être consommée sans danger, l'eau doit donc être traitée et surveillée en permanence [6]. Les techniques ont d'ailleurs beaucoup évoluées, faisant aujourd'hui du traitement de l'eau une industrie de pointe. La qualité de l'eau est garantie par le contrôle et la surveillance permanente des services qui s'occupent du traitement et de la distribution. Aujourd'hui, l'eau potable représente l'un des produits alimentaires les plus surveillés dans le monde.

Pour cela, le domaine de la surveillance de l'eau est sous une pression croissante pour produire une eau potable d'une plus grande qualité et à moindre coût. Ceci représente une économie en termes de coût mais aussi en termes de respect de l'environnement [7]. En effet, l'eau présente des caractéristiques bien spécifiques qu'il est indispensable d'en tenir compte dans la construction d'une démarche globale de prévention des risques. La maîtrise de la qualité sanitaire de l'eau pallie sans aucun doute les conséquences graves qui se concrétisent au niveau des risques encourus pour la santé publique [8]. L'exigence d'une réglementation très stricte des pouvoirs publics dans ce domaine est donc bel et bien justifiée.

Les usines de production d'eau potable ont deux fonctions principales : répondre à la demande en eau et assurer un niveau élevé de qualité de l'eau [8]. Cela nécessite un suivi permanent des différents procédés de traitement et des paramètres liés à la qualité de l'eau à l'entrée, aux différentes étapes de traitement et à la sortie de l'usine [9].

Ces dernières années, des efforts considérables ont été faits pour développer des techniques et des méthodes de surveillance, de diagnostic et de contrôle automatique de ces processus.

Ces méthodes peuvent être divisées en deux catégories : l'une basée sur l'existence de modèles formels, et l'autre basée sur l'analyse des variables et les connaissances préalables d'experts humains [10]. L'inconvénient de la première catégorie est que le modèle physique comporte des incertitudes et ne peut pas prendre en compte tous les paramètres de surveillance nécessaires. La deuxième catégorie, assez divisée en deux catégories, correspond aux outils de traitement du signal, souvent appelés outils de traitement de bas niveau, et la catégorie dite de haut niveau, dont les outils sont plutôt orientés vers la communication avec des opérateurs experts [11]. Cela représente les techniques de l'intelligence artificielle (IA) qui servent comme un outil de base pour l'aide à la décision. Leurs réponses sont plus élaborées et peuvent être obtenues à partir de données brutes issues de sorties de traitement de bas niveau. Il est judicieux de supposer que le problème de surveillance de la qualité de l'eau peut être considéré comme un problème de reconnaissance de formes, où les entrées représentent un ensemble d'observations ou de mesures liées aux caractéristiques de l'eau et les sorties correspondent à différentes décisions souhaitées de la qualité de l'eau.

Le contrôle, la surveillance et le diagnostic efficace des procédés est fortement dépendant de la précision et de la fiabilité des capteurs. Etant donné la grande variabilité de l'entrée du système (eau) et l'hétérogénéité des données délivrées par des capteurs de principes physiques très différents, de nombreux paramètres du procédé peuvent être mesurés en continu à l'aide de capteurs physiques relativement simples et peu onéreux. A l'opposé, la détermination de certaines quantités exige des analyses de laboratoire plus coûteuses qui ne peuvent être exécutées en ligne [9]. Les questions qui se pose ; est ce que les données effectuées sont-elles mesurables et vraisemblables ? Le système est-il en bon état de fonctionnement pour prendre une décision ? Le système présente-t-il des anomalies? Peut-on localiser ces anomalies ? Malgré les défauts, le système peut-il remplir sa mission ? C'est ça les différentes fonctions à résoudre dans les trois objectifs signalés : Le contrôle, la surveillance et le diagnostic.

De nombreuses recherches ont été menées ces dernières années pour apporter des solutions aux problèmes posés : Surveillance, diagnostic et contrôle, on prend par exemple l'approche "capteur logiciel" (ou *soft sensors*, en anglais) », dont la fonction consiste de

fournir à l'utilisateur une information complexe non observable directement, telle qu'un paramètre physico-chimique non mesurable en continu (ou à un coût prohibitif), sous forme d'un indice global de la qualité de l'eau. Ces informations seront ensuite utilisées comme données d'entrée dans les programmes de contrôle et de diagnostic de la partie amont de la station de production d'eau potable. La construction de capteurs logiciels peut être considérée comme un problème d'apprentissage des relations entre les variables à partir des données d'observation à base de régression, comme l'indice de qualité ou la dose de coagulant. Ces types de capteurs sont spécialement programmés à l'aide d'algorithmes dérivés de l'intelligence artificielle (IA) [1]. Parmi les techniques d'IA utilisées, on trouve les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM) et la mémoire longue à court terme (LSTM). Celles-ci se démarquent des autres outils par leur capacité d'apprentissage et de généralisation, notamment dans les applications de grande dimension. Ces techniques peuvent être utilisées en raison de leurs robustesses et de leurs capacités dans la prise en compte de la nature dynamique et complexe du procédé [12]. Ces techniques sont de plus en plus acceptées dans l'industrie de production d'eau potable en tant qu'outil de modélisation et de contrôle de procédés.

Les techniques conventionnelles ne sont pas adaptées et ne peuvent donc pas donner de meilleures performances pour les applications en temps réel car le temps de calcul et la complexité sont élevés avec une inaptitude appropriée en raison des relations non linéaires entre toutes les variables de modélisation. Le nombre d'études appliquant des modèles basés sur RNA et SVM qui ont été largement utilisés dans la surveillance de la qualité de l'eau a considérablement augmenté depuis ces dernières années [13, 14, 15]. Les limites des réseaux de neurones artificiels classiques est également qu'il n'y a pas de mémoire associée au modèle. Qu'est-ce qui pose problème pour les données séquentielles, comme le texte ou les séries chronologiques. La théorie de l'apprentissage statistique et la minimisation des risques structurels sont les fondements théoriques des algorithmes d'apprentissage des SVM. La méthode SVM est considérée comme l'un des classificateurs et approximateurs puissants et universels avec un degré de précision hautement souhaité dans l'apprentissage automatique [16]. Le réseau de neurones récurrent (RNN), un algorithme couramment utilisé et familier dans la discipline de l'apprentissage en profondeur (DL), qui a été suggéré pour la première fois en 2006, peut contrôler fortement les déficiences des réseaux de neurones artificiels classiques et exploiter les informations profondes des données [17]. Généralement, DL offre de grandes capacités, de manière

efficace et flexible de l'étape d'apprentissage et contient des couches cachées non linéaires multiples et variables [18]. La mémoire longue à court terme (LSTM) est l'une des architectures célèbres de DL qui est populaire en raison de ses performances élevées dans divers domaines et applications [19]. Les réseaux LSTM sont une extension de RNN principalement introduite pour gérer les situations où cette architecture échoue. Il peut mémoriser les informations précédentes et les appliquer au calcul de la sortie actuelle. Il résout le problème de la disparition du gradient dans les réseaux de neurones récurrents traditionnels en mémorisant ou en oubliant sélectivement certaines données [18], qui ont une capacité de mémoire à long terme et conviennent au traitement des données sur la qualité de l'eau [19]. Par conséquent, LSTM est conçu de manière à ce que le problème de gradient soit presque complètement supprimé dans les réseaux de neurones récurrents traditionnels, tandis que le modèle d'entraînement reste inchangé.

Deux opérations majeures impliquées dans les techniques d'apprentissage automatique sont l'extraction de caractéristiques et la classification ou régression. Le processus d'apprentissage pour la classification ou la régression est une étape nécessaire à la décision sur l'état de la qualité de l'eau. Dans le but d'assurer une bonne décision et une bonne performance du modèle, la préparation des entrées de données est nécessaire et nécessite un traitement particulier. L'utilisation de la sélection de caractéristiques pour les entrées de données sans aucune transformation pour éviter la redondance a suscité une attention considérable [20]. Les avantages de la sélection des caractéristiques incluent une réduction de la quantité de données et du temps d'exécution, en évitant la redondance, la réduction des capteurs en entrée dans le système de surveillance, le faible coût et l'amélioration de la précision de la modélisation.

L'analyse des données sur la qualité de l'eau semble une tâche difficile car les données ont des interactions complexes entre elles, multidimensionnelles, variables et non linéaires [19]. Les techniques de surveillance et diagnostic basées sur les statistiques sont préférables pour mettre en œuvre l'extraction de connaissances dans les données sur la qualité de l'eau. Les méthodes d'analyse multi-variée et de regroupement, telles que les cartes de caractéristiques auto-organisées de Kohonen (SOFM) [21], Classification ascendante hiérarchique (CAH) et l'analyse en composante principale (ACP). Elles peuvent également être utilisées pour analyser et traiter des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants, d'excellentes capacités de visualisation et d'interprétation dans la classification, les relations internes des

échantillons et leur indice, le regroupement et la réduction du bruit et classification [21, 22].

Dans ce travail de thèse, l'objectif est le développement des modèles de connaissance à partir des données caractéristiques de l'eau brute, comme des outils d'aide à la décision pour la surveillance, le diagnostic et le contrôle de la qualité d'eau potable dans son ensemble. Trois parties de la thèse a donc consisté à développer un outil permettant de décrire l'état de l'eau pour la surveillance par classification de données ou sous forme d'un indice global de la qualité de l'eau par régression, le développement d'un capteur logiciel de la dose du coagulant à injecter et pour le contrôle. Un autre outil peut également être utilisé pour analyser et traiter des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants, d'excellentes comme des opérations de diagnostic par la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs. Ces approches globales utilisant les méthodes de classification et de régression comme LSTM, SVM et RNA pour la surveillance, le diagnostic et le contrôle des systèmes de production d'eau en combinaison avec les méthodes SFOM, ACP et CAH pour la sélection des caractéristiques, le regroupement, la visualisation et l'interprétation des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants, est proposée. Les techniques d'apprentissage sont utilisées dans une étude comparative pour montrer l'évaluation des performances des modèles de surveillance et pour obtenir la meilleure décision et la solution adéquate en termes de précision (apprentissage et test) et de temps d'exécution. Nous étudions le potentiel de notre approche proposée pour obtenir une représentation efficace et une réduction de la dimensionnalité à l'aide de la méthode de sélection des caractéristiques et la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs, pour l'amélioration des résultats de classification binaire et de régression non linéaire des algorithmes d'apprentissage automatique supervisés.

Le travail réalisé est axé autour de quatre chapitres qui sont présentés comme suit :

Le premier chapitre est une description générale non exhaustive du vaste domaine de surveillance, de diagnostic et de supervision. Des généralités sur ce domaine et de son évolution, pour focaliser par la suite nos propos sur la partie « intelligente » de la surveillance et de diagnostic, notamment celle qui utilise les techniques de surveillance par Intelligence Artificielle (IA) et qui constitue le cœur de ce travail. La chaîne de production

et de traitement d'eau potable la plus courante, est de ce fait décrite. Notre application est enfin présentée en fin de chapitre, et l'approche adoptée pour le procédé de surveillance est également proposée.

Le deuxième chapitre est dédié principalement au prétraitement des données pour l'analyse, le traitement, le regroupement, la visualisation et l'interprétation des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants pour la classification et la régression. Nous décrivons les méthodes des cartes des caractéristiques auto-organisatrices de Kohonen (SOFM), Classification ascendante hiérarchique (CAH) et l'analyse en composante principale (ACP).

Dans le chapitre trois, nous détaillons les fondements théoriques des trois méthodes d'apprentissage statistique déjà évoquées. Après une brève introduction, où nous allons rappeler la notion de neurone formel, nous décrivons son architecture et rappelons les propriétés générales des réseaux de neurones artificiels (RNA) à apprentissage supervisé, ainsi que les réseaux de neurones récurrents tels que LSTM et SVM.

Le quatrième et dernier chapitre est consacré à la simulation et vise l'application des techniques étudiées précédemment comme étant une solution dans la conception de capteurs logiciels et de surveillance et diagnostic de la qualité de l'eau par reconnaissance de formes. L'objectif est de valider et d'évaluer les performances de chacune des méthodes présentées. Afin de mener une étude comparative permettant un choix décisif de la méthode la mieux adaptée à l'application proposée, on évaluera les paramètres liés au taux de reconnaissance, au temps d'apprentissage et à l'erreur pour ces différentes méthodes. Plusieurs exemples d'application sont prévus à cet effet, à savoir, le prétraitement des données pour l'analyse, le traitement, le regroupement, la visualisation et l'interprétation des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants, le contrôle de potabilité de l'eau en tant que problème de classification, le développement d'un capteur logiciel de coagulant et de l'indice de qualité vu comme un problème de régression.

Une conclusion générale en fin de cette thèse est prévue, elle retrace les différentes étapes réalisées et souligne les perspectives futures envisagées.

CHAPITRE I

SURVEILLANCE INDUSTRIELLE INTELLIGENTE ET TRAITEMENT D'EAU

Introduction

Le but principal dans les plupart des usines de production est de prévenir les pannes avant qu'elles ne surviennent et éviter les fausses alertes qui peuvent ralentir la production par la surveillance incessante de la progression de l'équipement à travers des mesures qualifiables et quantifiables avec le bon fonctionnement des installations dans le but de ne pas ralentir la production et assurer un niveau de qualité élevé et uniforme. Une demande croissante est apparue récemment dans des plusieurs applications industrielles en remplaçant les stratégies de maintenance curative par des stratégies de maintenance préventive. Le passage d'une situation de subir une défaillance à une situation de maîtriser cette défaillance nécessite la connaissance suffisantes des moyens des techniques d'analyse.

L'objet de ce chapitre est une description générale non exhaustive de ce vaste domaine de surveillance, de diagnostic et de supervision. Nous allons commencer par présenter des généralités sur ce domaine et de son évolution, pour focaliser par la suite nos propos sur la partie « intelligente » de la surveillance et de diagnostic, notamment celle qui utilise les techniques de surveillance par Intelligence Artificielle (IA). Ces systèmes de surveillance nécessitent de mesurer différents paramètres qualitatifs pour prendre une décision. Cette tâche est en premier lieu déléguée aux capteurs responsables de l'acquisition de l'information représentant les différents paramètres quantitatifs et qualitatifs afin d'assurer un contrôle automatique et efficace. Notre application est enfin présentée en fin de chapitre, et l'approche adoptée pour le procédé de surveillance est également proposée.

1.1. Maintenance et Surveillance Industrielle

1.1.1. La maintenance : Ensemble de toutes les actions techniques, administratives et de gestions directes correspondantes, y compris les opérations de surveillance et de contrôle, destinées à maintenir (maintenance préventive) ou à rétablir (maintenance corrective) un système en état de fonctionnement (disponibilité, fiabilité et sécurité), lui permettant d'accomplir une fonction requise [23]. La télémaintenance (aussi appelée téléassistance) d'un système est assurée par une communication informatique à distance entre l'unité et un centre spécialisé afin d'apporter une assistance technique, réaliser des opérations de dépannage (de matériel ou de logiciel), vérifier l'état du système ou encore réaliser un diagnostic en vue d'une intervention [24]. Différentes évolutions des politiques de la maintenance proposée dans la littérature, on trouve :

- **Maintenance réactive / corrective :** *exécutée après la détection et la localisation d'un défaut ou panne. Elle revient à corriger entièrement (curative-réparation) ou en partie (palliative-dépannage) le défaut observé [24].*
- **Maintenance préventive (préventive systématique) :** *C'est une intervention de maintenance prévue, préparée et programmée systématiquement à des intervalles prédéterminés avant la date probable d'apparition d'une défaillance ou d'une dégradation d'un service rendu [25].*
- **Maintenance prédictive (prévisionnelle, préventive conditionnelle) :** *Basée sur la surveillance en continu de l'évolution du système, afin de prévenir un dysfonctionnement avant qu'il n'arrive. Cette maintenance est basée sur l'analyse des mesures de certains paramètres de l'équipement : température, vibration, qualité des huiles, ..., pour tenter d'éviter un dysfonctionnement [24].*
- **Maintenance proactive (PRM) :** *Implique la surveillance et la vérification continue des causes primaires de défaillance du système surveillé*

Pour tous les systèmes de productions pilotées par microprocesseurs, la télémaintenance et la surveillance industrielle devient de plus en plus indispensable : celle-ci centralise en effet toutes les informations issues des multiples capteurs installés dans le système. Ces capteurs sont nécessaires et peut être facilement interrogée et modifiée à distance depuis l'unité de contrôle à travers des paramètres de réglage et un programme du pilotage du processus [24].

Depuis l'avènement des Nouvelles Technologies de l'Information et de la Communication (NTIC), le concept de télémaintenance a évolué vers la maintenance électronique (e-maintenance) :

- ✓ La télémaintenance est le concept de récupération de données à distance ou de contrôle à distance (temporaire) [24].
- ✓ La maintenance électronique (e-maintenance) est un concept lié aux principes des services web, de la coopération et du partage des connaissances (la collaboration au niveau de l'information, et la collaboration entre les personnes, les services et les entreprises [26].

Le passage de la maintenance classique à la maintenance à distance et en temps réel représente un enjeu important, au centre duquel la surveillance joue un rôle majeur, dans un contexte correspondant à une intelligence de plus en plus répartie. La tendance actuelle dans les systèmes de contrôle industriel est l'hybridation et la fusion de l'intelligence vers le bas (capteurs et actionneurs intelligents) afin d'en extraire un maximum d'informations élaborées, en temps réel et d'augmenter la réactivité du système de surveillance.

1.2. Surveillance industrielle : Définitions, Intérêt et Enjeux

La fonction surveillance automatique de l'évolution des équipements des systèmes et des procédés de production à travers des données quantifiables et qualifiables permet ainsi de prévenir un dysfonctionnement au niveau des installations ou une dégradation de la qualité des produits à fournir avant qu'il n'arrive et d'écarter les fausses alarmes qui peuvent ralentir la production [27]. Dans la littérature associée au domaine de la surveillance d'équipements industriels, on peut trouver plusieurs définitions et des notions de base quelquefois divergentes des termes de base utilisés en surveillance, qui sont indispensables au positionnement de notre travail de recherche.

1.2.1. Définitions

Plusieurs définitions sur la surveillance industrielle complètement différentes peuvent toutefois trouver en littérature. Ces définitions ont été extraites pour certaines à partir des références suivantes [7, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33] :

- **Dégradation** : Une dégradation représente une perte de performance d'une des fonctions fournies par un système.
- **Défaillance** : Une défaillance est une modification ou une cessation de la capacité d'un composant à remplir sa fonction requise conformément aux performances selon un seuil

d'arrêt défini dans cette spécification fonctionnelle et technique de l'équipement. Dans ce cas-là, il ne s'agit plus d'une dégradation mais d'une défaillance.

➤ **Panne** : Une panne est l'incapacité d'une entité (composant ou système) à exécuter la fonction requise.

Toute défaillance entraînera une panne sauf la possibilité d'erreurs de conception. En termes de temps, la défaillance correspond à une date (événement), et la panne correspond à une durée (état) entre la date de la défaillance et la date de fin de réparation.

➤ **Mode de fonctionnement** : Un système a généralement plusieurs modes de fonctionnement. Plusieurs types de modèles peuvent être observés, notamment :

- **Mode de fonctionnement nominal** : C'est le mode dans lequel un équipement ou un système industriel exécute ses tâches dans les conditions de fonctionnement requises par le constructeur et les exigences attendues par l'exploitant.

- **Mode de fonctionnement dégradé** : Cela correspond soit à la réalisation partielle de la tâche, soit à celle-ci avec des performances moindres. En d'autres termes, l'équipement ou le système s'est dégradé, mais n'est pas tombé en panne.

- **Mode de défaillance** : Cela correspond à la défaillance du système, c'est-à-dire à la défaillance suite à une dégradation ou à une panne brutale. Un mode de défaillance est caractérisé par les effets causés par cette défaillance. Ces effets peuvent être mesurables ou définissables. En effectuant une analyse causale des défaillances, nous pouvons relier les modes de défaillance à toutes les analyses effectuées par les experts. En d'autres termes, chaque mode de défaillance est associé à une décision et une explication possible. Chaque appareil ou système ne peut avoir qu'un seul mode nominal, mais il a plusieurs modes de défaillance.

➤ **Surveillance** : La surveillance est un dispositif **passif, informationnel**, qui analyse l'état du système ou du produit et fournit des indicateurs et mesures. La surveillance permet de faire la **détection** et la **classification** des défaillances en observant l'évolution du système, puis à les **diagnostiquer en localisant** les éléments défaillants et en **identifiant** les causes premières (Figure 1.1).

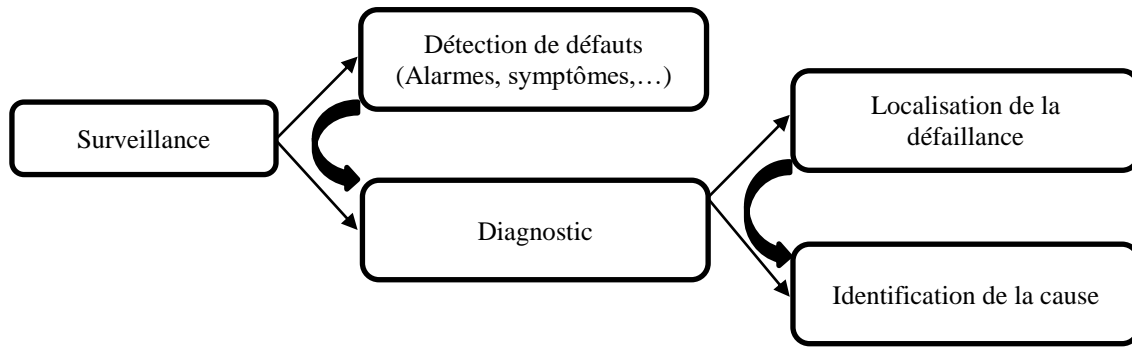


Fig. 1.1. Composantes de la surveillance industrielle.

- **Détection** : Afin de détecter les défaillances du système, il doit être possible de classer les conditions observables comme normales ou anormales.
- **Diagnostic** : Une simplification courante consiste à traiter tout ce qui est anormal comme une anomalie. Le but de la fonction de diagnostic est de **trouver la cause** et de **localiser** l'organe conduisant à une observation particulière.

La fonction de diagnostic est divisée en deux fonctions de base : localisation et identification. Sur la base de l'observation de l'état de panne, la fonction de diagnostic est chargée de trouver la cause première de la panne. Ce problème est difficile à résoudre. En effet, si pour une panne donnée il est facile de prédire la panne qui en résulte, la méthode inverse d'identification de la panne à partir de son impact est beaucoup plus difficile. Une défaillance peut généralement s'expliquer par plusieurs défauts. Ensuite, il faut faire une comparaison de différentes observations pour fournir la bonne interprétation [24].

➤ **La supervision**

Dans la plupart des configurations industrielles, la surveillance se fait en ligne à partir d'un ensemble des fonctions connexes, d'utiliser au mieux toutes les informations disponibles, qu'elles soient numériques (données capteurs), ou symboliques (historiques, environnements, réparations effectuées,...) et déterminer les causes des événements indésirables en positionnant la surveillance dans le cadre de la supervision [24, 27] (Figure. 1.2).

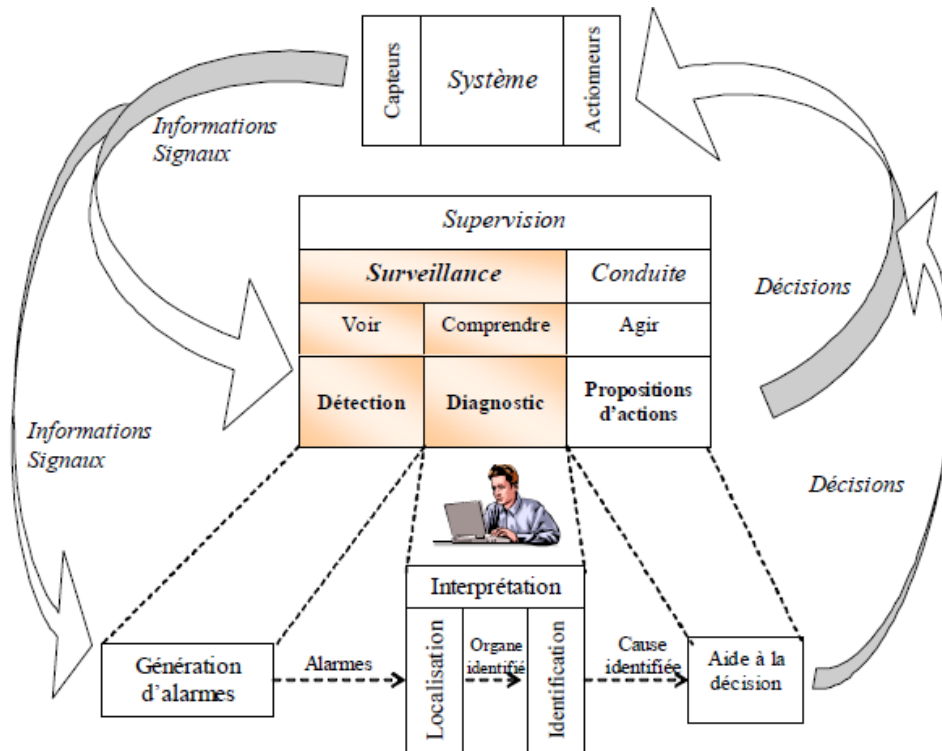


Fig. 1.2. Architecture générale d'un système de supervision en ligne [24].

L'ensemble : procédé, actionneurs, capteurs et partie de commande, constitue le système automatisé. Cette boucle s'échange des informations avec l'opérateur dont elle reçoit des consignes et à qui elle fournit des informations. Un système de supervision d'une installation consiste à réaliser cette boucle qui passe par l'opérateur. L'acquisition des données est la fonction qui relie la partie commande à la fonction de supervision. Les outils classiques de supervision doivent être complétés par des outils de surveillance, de diagnostic et d'aide à la décision (Figure 1.3).

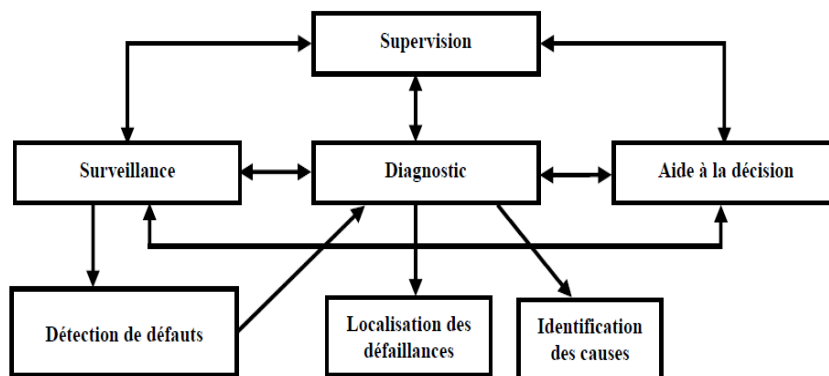


Fig. 1.3. Les outils de surveillance, de diagnostic et d'aide à la décision au niveau de la supervision [34].

La supervision consiste à gérer et à surveiller l'exécution d'une opération ou d'un travail accompli par l'homme ou une machine, puis à proposer des actions correctives [35]. La surveillance est une opération de recueil en continu des signaux de commande d'un procédé afin de reconstituer l'état de fonctionnement réel. Ainsi, la surveillance utilise les données à partir des capteurs provenant du système ou procédé pour représenter l'état de fonctionnement puis en détecter les évolutions. Si le capteur par exemple est en bon état, il donne des mesures correctes. La surveillance des équipements s'implique qu'en surveillant le procédé à produire. Le diagnostic identifie la cause de ces évolutions, puis le module d'aide à la décision propose des actions correctives.

L'impératif de sûreté de fonctionnement impose une maîtrise importante de ces techniques de surveillance, de diagnostic et d'aide à la décision, inclus la détection des défaillances, la configuration du processus et la maintenance. Ces techniques importantes devenues incontournables doivent s'insérer sans doute dans toute chaîne de production et de contrôle industriel.

➤ **Surveillance prédictive (dynamique)** : Comme la surveillance traditionnelle, la surveillance prédictive est un dispositif d'information **passif** qui analyse l'état actuel et passé d'un système et fournit des indicateurs sur les tendances futures du système. La surveillance prédictive comprend : la **détection prédictive (dynamique)** et le **diagnostic prédictif**, également appelé **pronostic**.

➤ **Détection prédictive (dynamique)** : La détection prédictive consiste à prévoir les pannes futures. En d'autres termes, le but de la détection prédictive est de détecter une dégradation plutôt qu'une défaillance.

➤ **Diagnostic prédictif (pronostic)** : Le but du diagnostic prédictif est d'identifier la cause et de localiser l'organe responsable d'une dégénérescence particulière (Figure. 1.4) [24].

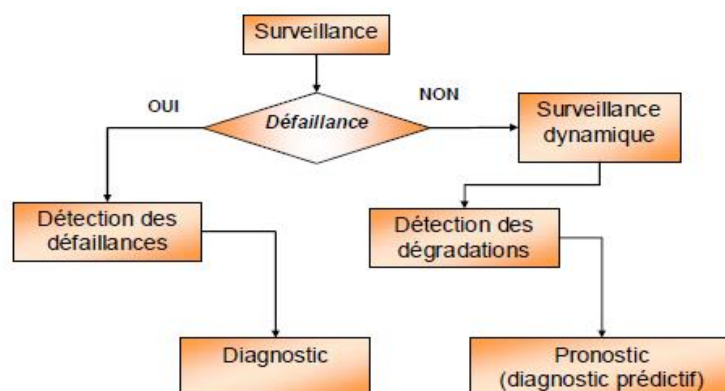


Fig. 1.4. Surveillance classique et surveillance dynamique [24]

1.2.2. Vers un système de surveillance intelligent

Les systèmes et les procédés industriels sont devenus de plus en plus complexes à cause au nombre continuellement croissant des variables nécessaires pour garantir leur bon fonctionnement. L'importance des informations et des mesures quantifiables et qualitatives disponibles sur le système surveillé vient du fait que :

- ✓ Ces paramètres ne sont pas conservatifs et changent instantanément.
- ✓ Les mesures sont relativement simples, rapides et peu coûteuses.

De nos jours, les procédés sont de plus en plus instrumentés (capteurs, régulateurs, actionneurs) et sont couplés à un ou plusieurs calculateurs numériques, destinés à l'acquisition de données et à la mise en œuvre de l'automatisation. Les premiers objectifs de cette automatisation accrue ont d'abord été [25, 36] :

- ✓ l'augmentation des performances du système de production ;
- ✓ la garantie de la qualité et la quantité du produit fabriqué ou fournie qui doit satisfaire un certain nombre de normes ;
- ✓ la diminution des coûts de fabrication ;
- ✓ les fonctions temps réel et différé

Par ailleurs, il est fréquent aujourd'hui que la supervision soit aussi chargée :

- ✓ de l'amélioration de la sécurité de l'installation industrielle, des hommes qui y travaillent et de l'environnement,
- ✓ de la traçabilité du produit.

Face à ces exigences et au flux d'informations dynamiques et variables, l'opérateur humain a besoin de nouveaux outils d'aide à la décision et de maintenance afin d'assurer de manière réactive et sur la conduite du procédé.

- **Les enjeux de la surveillance**

Malgré une automatisation accrue, l'opérateur se positionne encore comme le maillon « intelligent » de la boucle de surveillance : il a en charge d'analyser la situation par la mise en place d'interfaces ergonomiques donnant différentes vues du procédé sous forme de synoptiques, de prendre la décision adéquate et affichent en temps réel les grandeurs mesurées [36]. De plus, suite à une défaillance ou une dérive, les moyens de réaction sont souvent manuels ou semi-automatiques. Toutefois, cette tâche est de plus en plus difficile pour l'opérateur. Il peut prendre de mauvaises décisions et commettre alors une erreur

irréparable produisant des accidents industriels. Ces accidents ont un impact financier, sécuritaire et environnemental. À ces incidents quotidiens, s'ajoutent des accidents chimiques, des catastrophes écologiques et humaines qui soulignent la nécessité d'une surveillance avancée dans les systèmes complexes. De ce fait, automatiser cette fonction peut améliorer les performances du système physique et la sécurité du dispositif industriel et de son environnement.

Pour résumer toutes les définitions que nous avons présentées précédemment, nous illustrons sur la figure 1.5, un exemple d'une boucle de supervision (surveillance + action) d'un équipement industriel (capteur par exemple). Cette figure synthétise l'ensemble des fonctions connexes, en positionnant la surveillance dans le cadre de la supervision [25]. Dans la plupart des configurations industrielles, la surveillance se fait en ligne. La surveillance ici a pour but de contrôler l'équipement et par conséquent le procédé à surveiller. La *dégradation* de l'équipement ou du processus à contrôler se caractérise pour toute la période où l'amplitude des vibrations croît sans que le signal n'atteigne le seuil d'alarme. La *détection* du franchissement de ce seuil provoque une génération d'alarme, synonyme d'un évènement de défaillance de l'équipement. Alors, un équipement en bon état représente une garantie en soit pour des mesures correctes à chaque étage de la chaîne de production




Fig. 1.5. Exemple d'une boucle de supervision (surveillance + action) [25, 34].

Pour surveiller en continu l'évolution d'un système et déterminer les causes des évènements indésirables, il semble donc intéressant d'utiliser au mieux toutes les informations disponibles, qu'elles soient numériques (données capteurs), ou symboliques (historiques, environnements, réparations effectuées, etc.). Avec l'approche analytique, on considère les informations quantifiables issues d'un modèle numérique fournissant des symptômes analytiques. L'approche heuristique permet de compléter la première en prenant en compte les informations qualitatives sur les systèmes surveillés tirées de l'expertise humaine

1.3. Méthodes de Surveillance et intelligence artificielle

Les systèmes temps réel combinent à la fois des éléments matériels et logiciels (systèmes embarqués), ce qu'ils introduisent une complexité supplémentaire. Le maintien de la sécurité et d'un fonctionnement ininterrompu de ces systèmes est devenu un enjeu important. Le but de la surveillance dans un but de diagnostic d'un processus est d'identifier les causes d'un ensemble de symptômes observés qui indiquent une dégradation du produit fourni ou une panne au niveau des installations et de certains composants du système conduisant à un comportement anormal du système physique. Une classification globale des méthodes de surveillance est montrée dans la figure 1.6, cependant de nombreuses classifications sont proposées dans la littérature [7, 10, 24, 37, 38]. Ces classifications sont influencées par les domaines d'application particuliers et des utilisations spécifiques à chaque communauté et ne sont donc pas homogènes. Les méthodes de surveillance sont généralement divisées en deux catégories : les méthodes de surveillance avec et sans modèle [39].

- La première dépend de l'existence d'un modèle formel de système, utilisant souvent des techniques de l'automatique qui sont souvent préférables, notamment dans un contexte dynamique [40].
- Les méthodes de surveillance sans modèle sont utilisées lorsque les modèles des systèmes n'existent pas ou sont difficiles à obtenir et elles sont divisées en deux parties. La première répond aux outils statistiques de traitement du signal, souvent appelés outils de bas niveau puisque ils sont en contact direct avec les signaux des capteurs et ne servent généralement qu'à générer des alertes brutes sans aucune information sur leur signification. Des outils statistiques effectuent des tests sur le signal acquis, et ces tests ne peuvent fournir qu'une détection de défaillances. La deuxième partie est celle des techniques dites de haut niveau qui sont plutôt orientées vers la communication avec un expert. Celles-ci

représentent les techniques de l'intelligence artificielle (IA) et servent comme outils de base pour l'aide à la décision. En conséquence, leurs réponses sont plus élaborées que celles des techniques de bas niveau, et ils sont capables de détecter, d'interpréter et de diagnostiquer les défaillances [24].

Les deux approches *Automatique/Intelligence artificielles* peuvent être combinées et fusionnées pour obtenir plus d'avantages. Les méthodes analytiques basées sur l'Automatique sont par nature proches du système surveillé, puisqu'elles travaillent directement à partir de données des capteurs ; elles sont ainsi principalement utilisées pour la génération d'alarmes. Les méthodes de l'Intelligence Artificielle sont, elles, plus tournées vers la communication avec l'expert humain et se focalisent sur la transformation d'un ensemble de données brutes et non reliées entre elles en une information interprétable directement par l'opérateur chargé de la conduite ; elles sont donc utilisées pour l'interprétation des alarmes et l'aide à la décision. Dans le cas de l'utilisation des outils de l'Intelligence Artificielle, la fonction surveillance dans un but de diagnostic est souvent vue comme une application de reconnaissance des formes où celles-ci représentent le vecteur d'entrée composé des différents données observées sur le système (données mesurables et qualifiables) et les classes représentent les différents modes de fonctionnement souhaités. Un problème de diagnostic peut se définir comme un problème de reconnaissance de forme. L'ensemble des états est homologue à un ensemble de classes et le vecteur forme est le vecteur des composantes des paramètres observés sur le système [41].

Par conséquent, trouver la cause de la panne ou une dégradation devient une étape essentielle et nécessite différentes techniques [42, 43, 44]. Le diagnostic - comme toute surveillance - porte à la fois sur des données numériques (par exemple, l'utilisation des observations dans le cas des capteurs) et sur des données symboliques (la connaissance du système considéré). Dans ces travaux [24, 45, 46, 47, 48, 49], les deux techniques ont été conjointement utilisées.

Le problème de la surveillance avec un aspect complémentaire qui nous paraît fondamental, notamment par rapport au diagnostic qui – comparé à la détection de défauts/défaillances – ne peut pas se résoudre uniquement à une reconnaissance de formes.

La partie suivante est consacrée à la classification des méthodes de surveillance, en tenant compte particulièrement des critères associés au diagnostic.

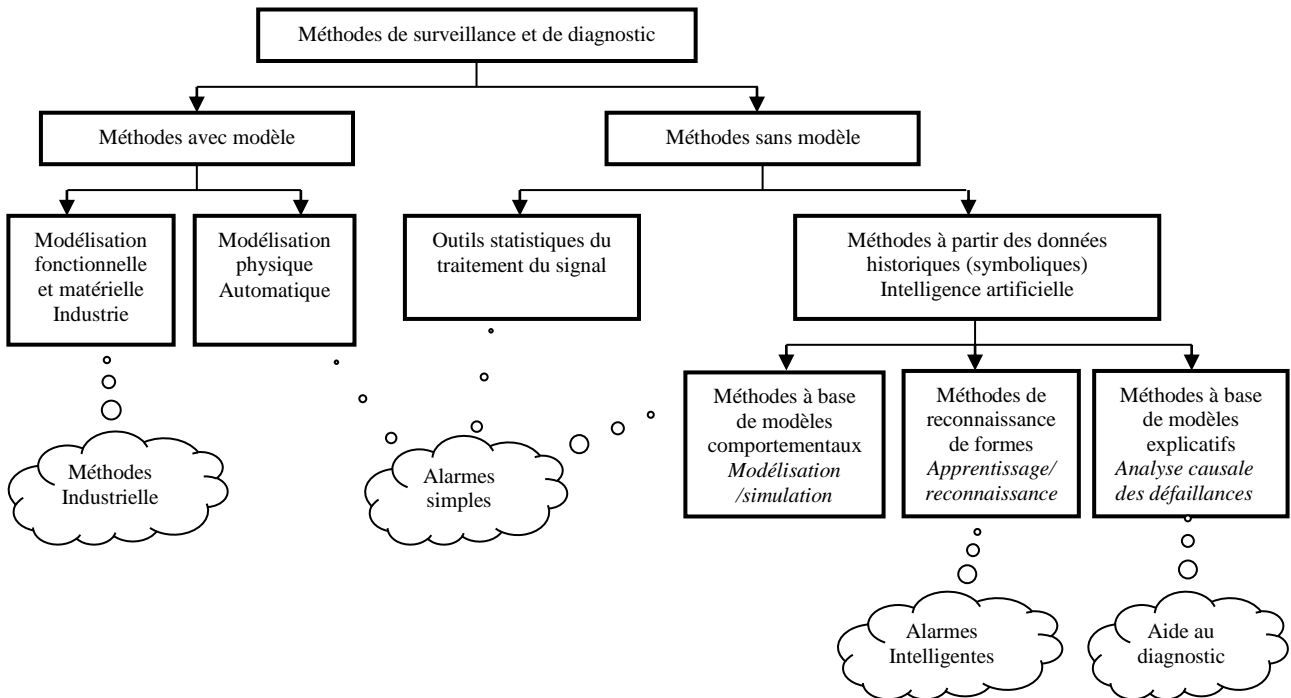


Fig.1.6. Classification globale des méthodes de surveillance et de diagnostic [7, 25, 34].

1.3.1. Méthode de surveillance à base de modèle

Les méthodes les plus utilisées à l'heure actuelle sont vraisemblablement celles qui sont basées sur l'utilisation des principes fondamentaux de la physique. Ceci est traduit par un ensemble de relations qui décrivent les interactions entre les différentes variables d'un processus donné. Ces relations peuvent impliquer deux catégories de méthodes : les méthodes de surveillance par modélisation fonctionnelle et matérielle, et les méthodes de surveillance par modélisation physique.

- **Les méthodes de surveillance par modélisation fonctionnelle et matérielle :** Ce type de méthodes consiste à concevoir des liens entre les causes initiales des défaillances et leurs effets mesurables. Les méthodes les plus couramment rencontrées sont l'Analyse des Modes de Défaillance de leurs Effets et de leur Criticité (*AMDEC*), les Arbres de Défaillances et les Digraphes (*ADD*) [36, 37]. Les arbres de défaillance utilisent le chaînage arrière ou simulation arrière jusqu'à trouver un événement primaire qui serait une des possibles causes de la déviation de comportement du procédé observé. Les digraphes signés sont une autre représentation d'une information causale dans laquelle les variables du processus sont représentées par des nœuds de graphes et les relations causales par des arcs [7]. Une limitation importante de ces méthodes réside dans la génération d'un grand nombre d'hypothèses pouvant conduire à une résolution erronée du problème ou à une

solution très incertaine. Ceci est dû en partie aux ambiguïtés de nature qualitative qui y sont manipulées.

- **Les méthodes de surveillance par modélisation physique** : ces méthodes reposent sur les relations mathématiques qui existent entre les variables. Elles sont les plus familières aux automaticiens [24]. Les modèles sont développés en utilisant les lois fondamentales de la physique. Elles supposent une connaissance approfondie du procédé sous forme de modèle numérique de type entrée-sortie. Ces méthodes ont pour principe de comparer les mesures effectuées sur le système aux informations fournies par le modèle [50]. Tout écart est alors synonyme d'une défaillance. Les outils de la théorie de la décision sont ensuite utilisés pour déterminer si cet écart est dû à des aléas normaux, comme par exemple le bruit de mesure, ou s'il traduit une défaillance du système. En général, ces méthodes peuvent être séparées en deux techniques : techniques de redondance physique et analytique, et techniques d'estimation paramétrique [10, 51].

1.3.2. Méthode de surveillance sans modèle

Il existe de nombreuses applications industrielles où les modèles sont difficiles à construire, voire impossibles à obtenir en raison d'une complexité accrue ou d'une reconfiguration importante du processus de production. Une large quantité de données enregistrées sur le fonctionnement du système (normal et au cours de défaillance) est nécessaire. Pour de telles applications industrielles, les seules méthodes de surveillance opérationnelles sont celles sans modèles. Deux méthodes existent dans ce cas : surveillance avec des outils statistiques de traitement du signal, et surveillance par des méthodes d'intelligence artificielle (à partir de données historiques).

- **Surveillance utilisant des outils statistiques de traitement du signal** : les outils statistiques de détection de défauts reposent sur l'hypothèse que le signal fourni par le capteur possède certaines propriétés statistiques. Ces propriétés sont identifiées par des tests qui permettent de vérifier si elles sont présentes dans un échantillon des signaux mesurés prélevés en mode de fonctionnement normal. Parmi les plus importants, on trouve : le test de franchissement de seuil et les tests de moyenne et de variance [10, 51].

- **Surveillance par des méthodes à partir de données historiques (intelligence artificielle)** : Ces méthodes s'appuient largement sur les techniques de l'Intelligence Artificielle qui permettent de pallier la complexité des systèmes à diagnostiquer. Généralement, l'Intelligence Artificielle est relativement bien adaptée aux problèmes de surveillance et de diagnostic. Une première approche consiste à considérer la surveillance

par reconnaissance de formes suivant une approche probabiliste, une approche floue ou une approche neuronale [41]. Globalement, ces méthodes seront regroupées sous l'expression : "*Méthodes à partir de données historiques ou Méthodes d'Intelligence Artificielle*". Cette classe comporte trois modèles : les méthodes à base de modèles comportementaux, les méthodes de reconnaissance de formes et les méthodes à base de modèles explicatifs (Figure 1.7).

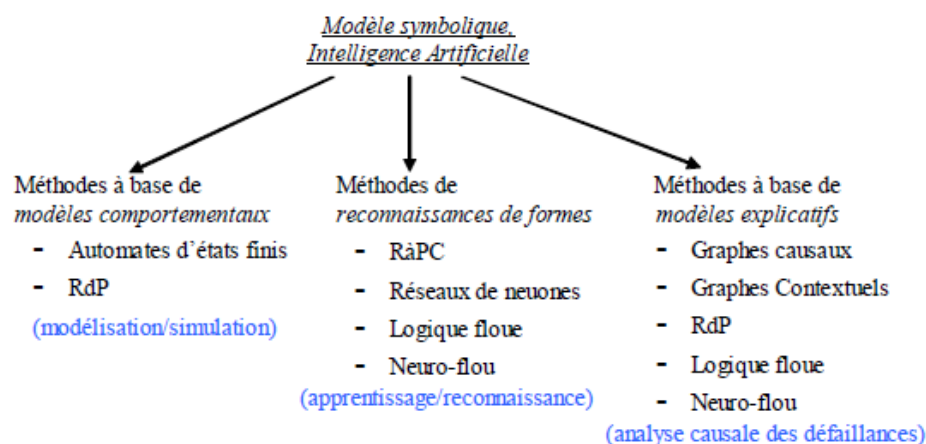


Fig. 1.7. Les outils d'IA sont classés en fonction de la méthode de diagnostic [24].

En effet, l'utilisation de l'intelligence artificielle permet de s'affranchir de la complexité du système à diagnostiquer. De plus, en général, l'intelligence artificielle est plus adaptée au diagnostic des problèmes en raison de ses caractéristiques. En effet, l'IA peut être caractérisée par sa puissance de traitement : grandes quantités de données, données non uniformes (chiffres/symboles), données contextuelles et données incomplètes.

- **Les méthodes à base de modèles comportementaux** : ces méthodes consistent à simuler le comportement du système à partir d'une modélisation de son comportement. Le plus souvent il s'agit de modèles "*de bon fonctionnement*" qui, contrairement aux modèles numériques, ne sont pas basés sur la physique du système mais sur une considération en termes de mode de fonctionnement. Ces méthodes regroupent deux principales familles : les réseaux de Petri et les automates d'états finis, qui seront caractérisées par les termes de *modélisation/simulation* [24, 25].

- **Les méthodes de reconnaissance de formes** : ces méthodes regroupent les modèles associatifs et les méthodes de reconnaissance dans le sens où elles sont caractérisées par les termes *apprentissage* et *reconnaissance* qui s'appliquent aussi bien aux systèmes de reconnaissance de formes qu'aux systèmes à base de règles tels que les systèmes experts. Dans ces méthodes, on retrouve principalement des outils tels que les méthodes statistiques

de reconnaissance de formes, les réseaux neuronaux, SVM, Analyse en Composantes Principales (ACP), logique floue, les réseaux neuro-flous, les systèmes experts et le raisonnement à partir de cas (RàPC). Les mots clés qui caractérisent le mieux ces approches sont : *apprentissage/reconnaissance* [7, 25].

- **Les méthodes à base de modèles explicatifs** : ces méthodes sont basées sur la formulation des relations entre les défaillances, leurs causes et leurs effets observables. Ces méthodes consistent à trouver la cause d'une défaillance à partir de ses symptômes observables. Certains outils d'intelligence artificielle permettent cette formalisation des connaissances disponibles sur le système. Parmi ces méthodes, on trouve les outils tels que : les graphes de fluence, les graphes causaux, les graphes contextuels, les réseaux de Petri et la logique floue [11]. Le mot clé associé est l'*analyse causale* [7, 24].

1.4. Les étapes de traitement et production des eaux potables

Le traitement de l'eau est tout processus qui améliore la qualité de l'eau pour la remettre plus adaptée à une utilisation finale spécifique. Les utilisations finales peuvent être les boissons, l'approvisionnement en eau industrielle, l'irrigation, l'entretien des rivières, les loisirs aquatiques ou de nombreuses autres utilisations, y compris le retour en toute sécurité dans l'environnement. Le traitement de l'eau élimine ou réduit la concentration de contaminants et de composants indésirables afin que l'eau convienne à l'utilisation finale souhaitée et évite le risque d'effets néfastes sur la santé à court ou à long terme. Ce traitement est vital pour la santé humaine, permettant aux humains de bénéficier de l'eau potable et de l'irrigation.

La figure 1.8 représente la chaîne habituelle la plus complète et la plus courante dans une usine de potabilisation appliquée à une eau de surface qui comporte 5 grandes étapes qui sont : prétraitement, pré-oxydation, clarification (coagulation, floculation-décantation ou flottation, filtration), oxydation-désinfection, traitement d'affinage [7, 9, 52, 53].

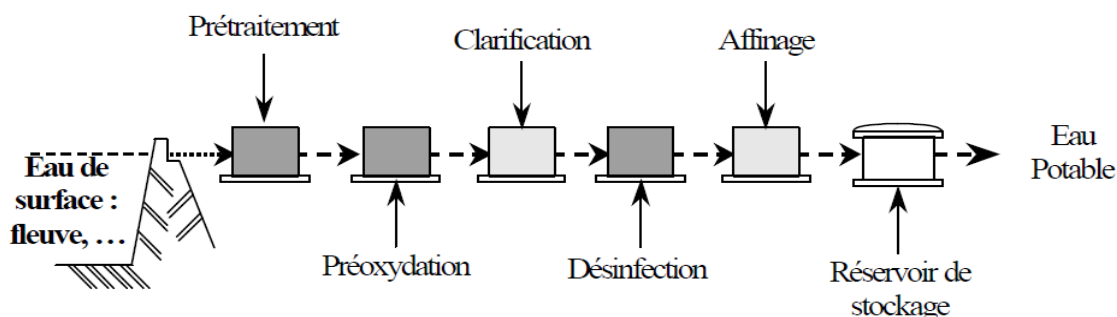


Fig. 1.8. Chaîne de traitement et de production d'eau potable [9, 24].

1.4.1. Prétraitement

Avant traitement, l'eau doit être éliminée du plus grand nombre possible d'éléments dont la nature et la taille empêcheraient un traitement ultérieur. Dans le cas de production de l'eau potable, il existe deux principaux types de prétraitement :

– le dégrillage, la première station de traitement, protège les ouvrages en aval de l'arrivée d'objets volumineux susceptibles de provoquer le colmatage des différentes unités de traitement. Cela permet également de séparer et de drainer facilement les matériaux en vrac transportés par l'eau brute, ce qui peut affecter l'efficacité du traitement ultérieur ou compliquer son exécution. Le dégrillage est principalement utilisé pour éliminer les gros objets : copeaux de bois, etc.

– le tamisage, le tamisage, en revanche, élimine les objets plus fins que le tamisage n'enlève. Par exemple, ce sont des morceaux de plastique. [9]

1.4.2. Pré-oxydation

L'oxydation est la dernière étape du traitement de l'eau potable avant sa distribution. Il élimine les micro-organismes pathogènes dans l'eau, mais certaines bactéries communes peuvent rester dans l'eau car la désinfection n'est pas la stérilisation (stérilisation = destruction de toutes les bactéries présentes dans l'environnement) [54]. La pré-oxydation se déroule de trois manières différentes : ajout de Chlore (pré-chloration), ajout de dioxyde de chlore et ajout d'ozone (pré ozonation).

1.4.3. Clarification

La clarification est un ensemble d'opérations qui permet d'éliminer les matières en suspension (minérales et organiques) des eaux brutes ainsi que les matières organiques dissoutes [55]. Selon la concentration de l'un et de l'autre des différents contaminants, des opérations de plus en plus complexes peuvent être nécessaires, allant de la simple filtration avec ou sans réactifs à la coagulation-floculation-décantation ou à la filtration par flottation. La clarification comprend les opérations suivantes : Coagulation, Floculation et Filtration [7].

L'étape de coagulation joue un rôle considérable dans le traitement des eaux de surface. 90% des usines de production d'eau potable sont concernées. La principale difficulté est de déterminer la quantité optimale de réactif à injecter en fonction des caractéristiques de l'eau brute. Cette opération a également un impact important sur les opérations ultérieures de

décantation et de filtration. D'autre part, des contrôles efficaces peuvent réduire les coûts de main-d'œuvre et de réactifs et améliorer la conformité de la qualité de l'eau après traitement.

En résumé, la maîtrise de cette opération est donc essentielle pour trois raisons : contrôler la qualité de l'eau traitée en sortie (pour réduire la turbidité), contrôler le coagulant résiduel en sortie (concernant la présence de coagulant résiduel, Réglementations strictes dans l'eau traitée) ainsi que la réduction des contraintes et des coûts d'exploitation (coûts des réactifs et de l'intervention humaine) [9].

- **But de la coagulation-floculation**

L'opération de coagulation-floculation a pour but de faire croître des particules (qui sont essentiellement des colloïdes) en déstabilisant les particules en suspension puis en formant des flocs plus gros - organiques naturels ou organiques synthétiques - (agrégation de colloïdes en un réseau tridimensionnel) par absorption et agrégation [56]. La floculation est le phénomène de formation de flocons. Contrairement à l'étape de coagulation, la floculation nécessite une agitation lente. Les flocs ainsi formés seront ensuite décantés et filtrés (Figure. 1.9) [7, 9].




Fig. 1.9. Coagulation-Floculation. [9].

Pour optimiser le processus de coagulation-floculation, plusieurs variables applicables doivent être prises en compte, telles que le pH, le dosage du coagulant, les conditions de mélange et la température.

- **La décantation-flottation**

La décantation est la méthode la plus courante pour séparer les solides en suspension et les colloïdes (s'agglomèrent sous forme de flocs après l'étape de coagulation-floculation). Il est bien connu que les particules dans une suspension décantent en fonction de leur taille, donc pour obtenir une bonne décantation, il faut augmenter le diamètre des particules, donc le phénomène de coagulation-floculation est impératif.

La flottation est préférée à la décantation dans la clarification de flocs légers à faible extrait sec, riches en plancton ou en algues, et produisant une faible décantation. Recommandé pour le traitement des boues. Ce processus est très souple à utiliser. Il permet l'épaississement simultané des boues directement déshydratables. L'efficacité de la flottation et de la décantation peut être obtenue par des mesures du pourcentage de boues retenues, de la quantité de matières organiques éliminées et de la turbidité [7, 9].

- **La filtration**

La filtration est un processus visant à clarifier les liquides en les faisant passer contenant des solides en suspension à travers un milieu poreux constitué de matériaux particuliers [57]. En effet, de très petites particules présentes à l'origine dans l'eau brute ou produites par floculation sont toujours présentes. La rétention de ces particules se produit à la surface des particules en raison de forces physiques. La facilité de fixation dépend des conditions de fonctionnement du filtre et du type de matériau utilisé. L'espace inter-granulaire définit la capacité de rétention du filtre. Au fur et à mesure que l'eau passe, cet espace diminue et le filtre se bouche. La chute de pression augmente fortement. Ensuite, un lavage à contre-courant doit être déclenché. La filtration peut éliminer correctement les bactéries, la couleur et la turbidité.

1.4.4. Désinfection

La désinfection est la dernière étape du traitement de l'eau potable avant sa distribution. Il élimine tous les micro-organismes pathogènes présents dans l'eau. Cependant, certaines bactéries courantes peuvent rester dans l'eau car la désinfection n'est pas la stérilisation. Les quatre principaux désinfectants utilisés dans la production d'eau potable sont : le chlore (Chloration), le dioxyde de chlore, l'ozone et le rayonnement UV [34].

- **Paramètres de contrôle**

Pour chaque type de processus de désinfection, différents paramètres doivent être contrôlés. Les paramètres suivis doivent permettre d'évaluer l'efficacité de la désinfection :

- *Température* : La prolifération microbienne s'accélère lorsque la température augmente. De plus, la consommation de désinfectants est plus importante. Il faut donc être vigilant sur l'évolution de ce paramètre et adapter les consignes de désinfection en conséquence.
- *PH* : La disponibilité du chlore présent dans l'eau varie avec le pH. Par conséquent, le pH doit être mesuré en même temps que le chlore libre afin d'évaluer au mieux l'efficacité du traitement.
- *Turbidité* : Il caractérise la présence de particules dans l'eau. La présence de turbidité est le signe d'un traitement incomplet. Les particules qui ne sont pas retenues lors du traitement « transporteront » des micro-organismes qui seront plus difficiles à inactiver par les désinfectants. Enfin, la turbidité prouve la présence de matières en suspension susceptibles de se déposer dans le réseau favorisant ainsi la prolifération microbienne et la protection contre l'action des désinfectants.
- *NH₄⁺ et NO₂⁻* : Ils sont consommés par le chlore et peuvent être désignés comme des indicateurs de pollution.

Ces contrôles sont généralement effectués en entrée ou en sortie du contacteur de désinfection, mais également en différents points du réseau [9, 34].

1.4.5. Affinage

Le traitement final implique un équilibrage du calco-carbonique. L'eau suit un cycle naturel et les éléments chimiques qu'elle contient évoluent. L'eau de pluie contient naturellement du dioxyde de carbone. En traversant la couche d'humus riche en acide, il devient très riche en dioxyde de carbone. Lorsqu'il est infiltré dans des sols calcaires (c'est-à-dire riches en CaCO₃), il captera les ions CaO₂⁺ et HCO₃⁻. En fait, le calcium est dissous dans de l'eau contenant du dioxyde de carbone. On dit qu'il est écaillant ou encroûtant. En revanche, lorsque l'eau de pluie traverse des roches pauvres en calcium (zones granitiques), elle contient encore beaucoup de dioxyde de carbone dissous. Cette eau est généralement acide. Ils ont dit qu'elle était agressive. Il y a généralement deux problèmes différents : corriger l'eau corrosive et corriger l'eau incrustée. L'eau corrosive peut être corrigée de plusieurs façons. Premièrement, le CO₂ peut être éliminé par aération. Du fait de l'élimination du CO₂, le pH augmente et se rapproche du pH d'équilibre.

Deuxièmement, un alcali peut être ajouté à l'eau. L'ajout d'une base permet d'élever le pH et d'atteindre un pH d'équilibre. L'eau de croûte peut être corrigée par traitement direct ou par décarburation pour réduire le potentiel d'entartrage. Le traitement direct correspond à l'ajout d'acide [7, 34].

1.5. Surveillance de la qualité de l'eau par reconnaissance de formes

L'approche de surveillance par reconnaissance de formes (ou par analyse des données), permet d'associer un ensemble de mesures effectuées sur le système à des états de fonctionnement connus. Cette fonction permet d'avoir une relation d'un espace de caractéristiques vers un espace de décision de façon à minimiser le risque de mauvaise reconnaissance. Les techniques de reconnaissance de formes sont nombreuses et pour certaines, les résultats sont globalement satisfaisants. Ces méthodes supposent qu'aucun modèle n'est disponible. Cependant, elles effectuent les opérations de perception, de classification et de prédiction. Ces méthodes sont basées sur les théories des probabilités et de l'Intelligence Artificielle. La première peut se montrer insuffisante car elle suppose une connaissance a priori de tous les états de fonctionnement et ne prend pas en compte l'évolution du système. La seconde a l'avantage de se baser plutôt sur une phase dite d'apprentissage. Leur principal avantage par rapport aux autres outils est leur capacité à apprendre et à généraliser leurs connaissances à des entrées inconnues. Le processus d'apprentissage est une étape très importante dans la réussite de ce type d'opération. Ces méthodes peuvent également être implémentées dans des circuits électroniques, offrant la possibilité d'un traitement en temps réel. L'une des caractéristiques de cet outil est qu'il est adapté au développement de systèmes de surveillance modernes, capables de s'adapter à des systèmes complexes avec de multiples reconfigurations. Parmi les techniques proposées, on trouve en particulier les systèmes experts, les outils statistiques de reconnaissance de formes, le raisonnement à partir de cas (*RàPC*), l'Analyse en composantes principales (ACP), des cartes auto-organisatrices de kohonen (SOFM), l'analyse en grappes (CA), les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM), logique floue, réseaux neuro-flous et Deep Learning. La figure 1.10 montre l'architecture générale qu'on peut imaginer d'une application de surveillance par reconnaissance de formes. L'expert humain joue un rôle primordial dans ce type d'applications. Toute la phase d'apprentissage supervisée dépend de son analyse des états du système où chaque état est caractérisé par un ensemble de données (formes d'entrée) recueillies sur le système. Après cette phase d'apprentissage, l'algorithme utilisé associera

les décisions correspondantes représentant ainsi les sorties du système aux formes d'entrée présentées. Le principal avantage de ces techniques est leur capacité d'apprentissage et de généralisation des données reçues en entrée. Ces techniques s'apprentent parfaitement pour une éventuelle mise au point de systèmes de surveillance capables de s'adapter à d'éventuelles extensions et reconfigurations multiples. Dans le travail que nous présentons dans le cadre de cette thèse, la surveillance de la qualité de l'eau potable peut être vue comme un problème de reconnaissance de formes, où les formes représentent l'ensemble des paramètres relatifs à la qualité de l'eau, et les sorties correspondent aux différents états de l'eau.

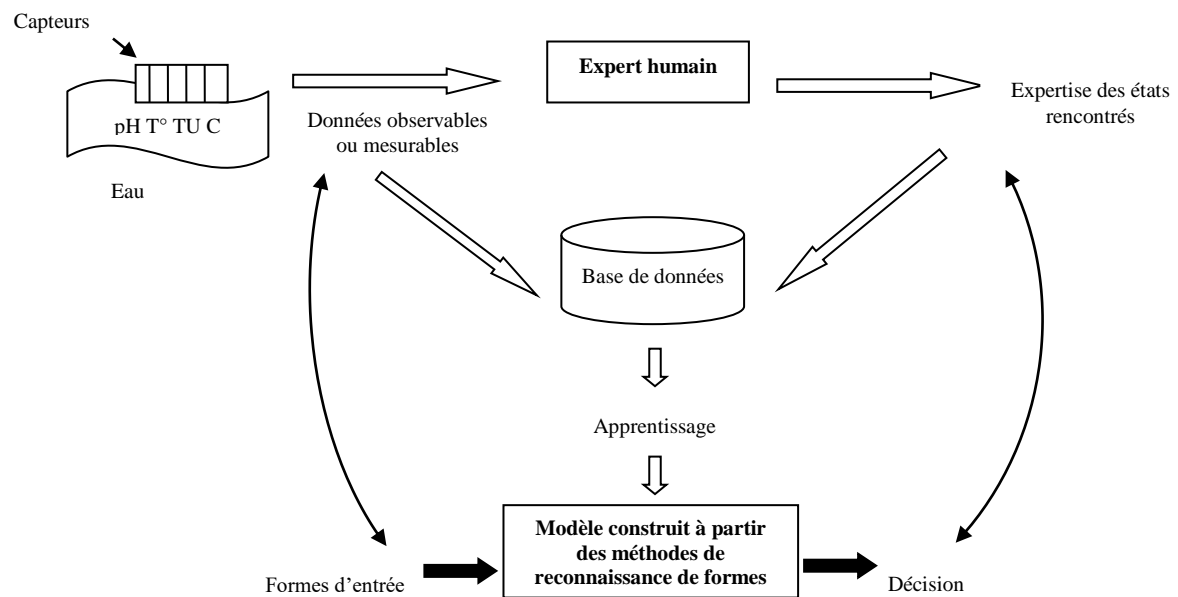


Fig.1.10. Schéma général du système de surveillance de l'eau par reconnaissance de formes [34].

Au niveau du système (figure 1.8), on peut supposer que les différents paramètres physico-chimiques utilisées, tels que le pH, la température (T°), la conductivité (C), la turbidité (TU), etc., sont transformés en signaux électriques à partir des capteurs, et transmis vers une station de contrôle qui assure l'acquisition, le traitement, l'analyse et la décision envisagée après chaque acquisition. Une suite d'acquisitions pourrait être exécutée plusieurs fois par jour, sous des conditions prédéfinies. Nous procédons donc lors d'une étape préliminaire d'apprentissage, à paramétrer le modèle pour la décision. Un module d'apprentissage supervisé par un expert, permet de collecter de manière continue les paramètres relatifs aux différents états de l'eau pour la mise en œuvre d'une base de connaissance complète pour le modèle de surveillance implanté. En général l'apprentissage

est une étape assez longue, et nécessite plus de temps de calcul. Ce critère (temps d'apprentissage) évoque un traitement hors ligne devant être effectué par le système de surveillance. Le système de contrôle doit donc pouvoir marier à la fois une surveillance et un diagnostic direct de l'eau et un apprentissage en arrière-plan (en différé).

Dans cette étude, lorsqu'on parle de la surveillance dans un but de diagnostic des systèmes de production de l'eau potable comme notre champ d'application, il s'agit en réalité de connaître en continu l'état de l'eau à partir de différents paramètres liés à la qualité de l'eau comme : pH, température, turbidité, conductivité, oxygène dissous,....etc. Traditionnellement, un certain nombre de mesures utiles de différents paramètres de l'eau brute sont généralement effectuées pour détecter sa qualité, tels que : le contrôle bactériologique, le contrôle de la désinfection et le contrôle physico-chimique, puis décidez votre propre état, puis chercher des techniques et des méthodes pour la rendre potable. Ces méthodes sont déterminées à l'aide de tests expérimentaux appelés Jar-tests. Le dosage optimal de coagulant recherché est fonction de la qualité des différentes eaux comparées. Généralement, dans les grandes usines, un seul test par jour est effectué.

L'automatisation de ces processus de surveillance permet de pallier certaines faiblesses humaines, de fiabiliser et d'améliorer les conditions d'exploitation et les performances des installations en supprimant les tâches les plus répétitives et fastidieuses pour les opérateurs. L'automatisation des processus peut avoir aussi divers objectifs, les plus courants étant d'améliorer les performances des systèmes de production, d'assurer la qualité des produits, de surveiller les usines et les équipements de traitement, de réduire les coûts de production et d'améliorer la sécurité des installations industrielles et de leurs environnements. De plus, l'automatisation associée au stockage de l'information permet des études statistiques des données collectées, ouvrant des pistes d'études de modélisation pour optimiser les processus de traitement.

Plus récemment, l'automatisation et la surveillance informatique ont accru le confort en permettant un meilleur contrôle, même à distance, d'un grand nombre d'informations issues de différents capteurs installés dans le système, simplifiant ainsi les tâches d'exploitation, de surveillance, de maintenance, de diagnostic et de gestion. Lorsque l'intervention d'experts dans le domaine ou le traitement d'informations qualitatives doivent être envisagée, l'utilisation de techniques issues du domaine de l'intelligence artificielle apparaît comme la principale alternative pour résoudre ces problèmes. Souvent, des niveaux supérieurs dans les systèmes modernes, tels que la supervision, sont ajoutés à la boucle de

contrôle pour s'assurer que les conditions de fonctionnement dans lesquelles l'algorithme de contrôle est valide sont estimées et contrôlées. Les tâches de supervision spécifiques comprennent la détection des défaillances, le diagnostic, la modification des points de consigne et la reconfiguration des lois de commande. Ces tâches sont effectuées par des opérateurs humains qui utilisent leur expertise pour prendre des décisions après avoir évalué les conditions du processus en fonction des variables observées.

Conclusion

Ce chapitre présente une brève introduction sur les différentes méthodes de surveillance industrielle et de diagnostic actuellement utilisées. Les différents procédés d'une chaîne de production d'eau potable sont alors aussi présentés. Le contrôle automatique basé sur une surveillance et un diagnostic par reconnaissance de formes à travers les différents paramètres quantifiables et qualifiables de l'eau, peut présenter une solution intéressante. Les méthodes de surveillance par intelligence artificielle sont avérées très efficaces pour résoudre les problèmes de surveillance et de diagnostic industriel. Par conséquent, les systèmes de surveillance utilisant la technologie de l'intelligence artificielle peuvent fournir aux experts humains d'excellents systèmes d'aide à la décision. En fin de ce chapitre, une architecture du système de surveillance de la qualité de l'eau illustrant cette approche est proposée. Le chapitre suivant va porter sur l'instrumentation et les paramètres quantifiables à mesurer. Il est consacré aux principaux paramètres descripteurs de l'eau (variables d'entrée), ainsi qu'aux capteurs correspondants, éléments précieux et incontournables se trouvant en amont de la chaîne de contrôle et de surveillance.

Le chapitre suivant fera l'objet d'une mise en œuvre théorique des techniques de l'analyse de données et des graphes dans un but de sélection des caractéristiques et de réduction de dimensionnalité sur des données multi sensorielles. L'objectif, rappelons-le encore une fois, est l'application de ces techniques comme étant une étape préliminaire de prétraitement de données dans la conception de capteurs logiciels et de surveillance de la qualité de l'eau par reconnaissance de formes.

CHAPITRE II

ANALYSE DE DONNEES

Introduction

L'apprentissage automatique est l'une des méthodes d'analyse des données les plus utilisées dans divers domaines. Elle a pour objectif d'identifier des groupes d'individus (ou d'éléments) ayant un comportement homogène vis-à-vis d'un certain nombre de caractéristiques. Les applications sont très nombreuses et concernent de nombreux domaines et méthodes de classification utilisées à l'analyse des données manquantes, des données mixtes (décrites par des caractères quantitatifs et qualitatifs à la fois) et sélection des caractéristiques.

La sélection de caractéristiques, également appelée sélection de variables, sélection d'attributs ou sélection de sous-ensembles de variables, est l'un des concepts fondamentaux de l'apprentissage automatique et a un impact considérable sur les performances du modèle. La sélection de caractéristiques peut être utilisée pour les tâches de classification ou de régression. L'objectif est de sélectionner un sous-ensemble d'entités à partir de l'ensemble de données d'origine, en utilisant le plus petit ensemble d'entités pour réduire sa dimensionnalité afin de représenter la plus grande quantité d'écarts dans les données. La sélection des fonctionnalités a deux objectifs principaux.

- Premièrement, la sélection des caractéristiques améliore généralement la précision de l'apprentissage en éliminant les caractéristiques non pertinentes, redondantes ou étroitement liées.
- En outre, cela réduit le nombre de fonctionnalités qui rendent le processus d'apprentissage du modèle plus efficace. L'efficacité est importante pour les apprenants dont l'apprentissage est coûteux, comme les machines à vecteurs de support.

Dans ce travail, on rappelle que nous adoptons comme solution la surveillance et le contrôle de la qualité de l'eau et cela par les techniques de reconnaissance de formes.

Dans le but d'analyse de données et afin de réduire la dimension des variables d'entrée, on utilise dans ce chapitre les techniques d'analyse suivantes : ACP : Analyse en Composantes Principales, les cartes auto-organisatrices de Kohonen (SOM) et la classification ascendante hiérarchique (CAH).

2.1. Etat de l'art

Aujourd'hui, de vastes données d'enquêtes sont dépouillées et, fournissent de grandes bases de données qui se prêtent aisément à l'interprétation. Des données issues d'investigations spécifiques sont rassemblées et constituent une masse importante et apparemment indéchiffrable d'informations mais, qu'on peut désormais traiter sans difficultés. Cependant, comment « extraire les phénomènes, les lois, les connaissances que recèlent ces données que nous ne pouvons appréhender directement » [58] ?

La statistique classique nous a habitués à étudier les variables les unes après les autres, de construire autant d'histogrammes que de variables. Comment faire pour que, à ces nombreux graphiques se substitue un seul graphique, une carte plane ? Comment devant, la profusion des descriptions parcellaires fournies par l'analyse variable par variable, donner une vision globale de l'ensemble des résultats ? Les techniques dites d'analyse des données permettent de répondre à ces questions.

Ces techniques qui sont essentiellement descriptives, ont pour but de *décrire*, de *réduire*, de *classer* et de *clarifier* les données en tenant compte de nombreux points de vue et d'étudier, en dégagant les grands traits, les liaisons, les ressemblances ou les différences entre les variables ou groupes de variables. Les données fournies sont qualifiées de « synthétiques, percutants et valent souvent mieux qu'un long discours ». Cette approche descriptive et multidimensionnelle permet de dire que l'Analyse des Données, c'est de la « statistique descriptive perfectionnée ». L'analyse des données recouvre principalement deux ensembles de techniques : « les premières qui relèvent de la géométrie euclidienne et conduisent à l'extraction de valeurs et de vecteurs propres, sont appelées *analyses factorielles* ; les secondes, dites de *classification automatique* sont caractérisées par le choix d'un indice de proximité et d'un algorithme d'agrégation ou de désagrégation qui permettent d'obtenir une partition ou arbre de classification [59]. Il s'agit de l'analyse en composantes principales (ACP) telle que l'analyse factorielle. La classification automatique sera introduite comme aide à l'interprétation d'une analyse factorielle. Ce qui permet de compléter et d'enrichir les résultats de cette dernière.

Le regroupement des individus similaires de caractéristiques dans une même classe c-à-d la structuration des données dans des classes homogènes est l'objectif principal de la classification automatique qui se divise en deux méthodes à approches différentes (Fig. 2.1) [60] :

- Méthodes à approche géométrique.
- Méthodes à approche probabiliste.

L'approche géométrique est considérée comme la fondation des méthodes de classification automatique des données qui utilise une mesure de proximité (distance ou dissimilarité) afin de comparer deux individus et d'affecter ceux qui sont plus probablement proches à une même classe.

La classification hiérarchique et les Self-Organizing Maps, SOM : cartes auto-organisatrices de Kohonen sont deux grandes méthodes de la classification automatique à approche géométrique qui ont la capacité de classifier les données tout en préservant leur topologie.

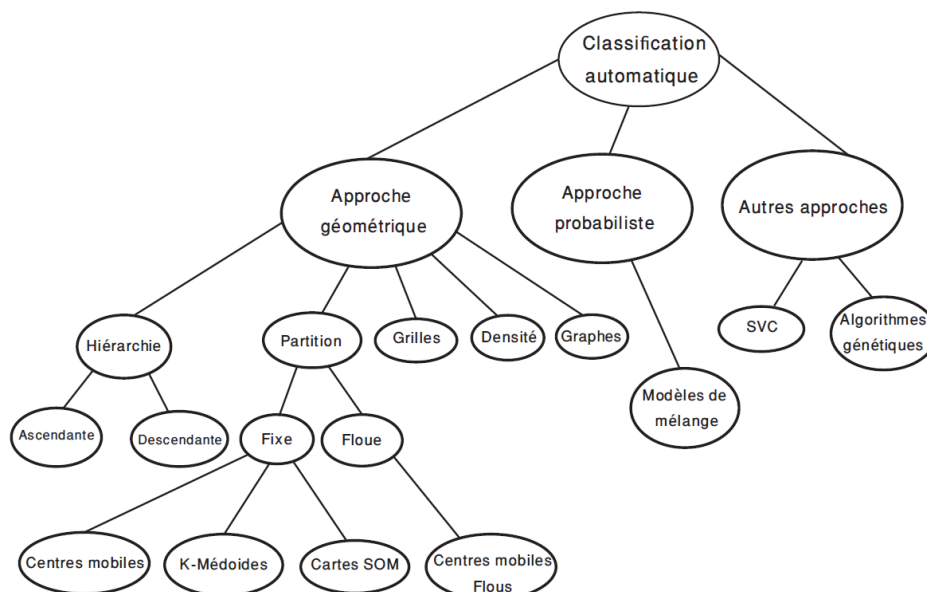


Fig. 2.1. Méthodes de classification non supervisée [60].

2.1.1. Méthodes géométriques

La classification de données dans les méthodes à approche géométrique est basée sur la mesure de proximité entre les individus. Si deux individus sont proches ; on dit qu'ils appartiennent plus probablement à une même classe. On distingue les méthodes suivantes :

la classification hiérarchique, les méthodes de classification par partitionnement, ainsi que les méthodes basées sur la densité, sur les graphes et sur les grilles [60].

La classification hiérarchique sert à mettre une hiérarchie sur l'ensemble des observations à l'aide d'une matrice de distances ou de dissimilarités entre individus [61] qui produira plusieurs partitions emboîtées dans un ordre ascendant ou descendant. Il s'agit donc respectivement d'une classification hiérarchique ascendante ou descendante ou divisive.

Avoir des partitions plus souples tolérant des données imprécises ou incertaines est assuré par les méthodes de classification par partitionnement menant à une seule partition de l'ensemble de données fixe où chaque observation appartient à une seule classe ; ou floue dont l'algorithme des *c*-moyennes floues (fuzzy *c*-means) à la capacité de fournir cette dernière et de minimiser itérativement une fonction coût [62]. Dont la représentation des classes est faite par leurs centres de gravité recalculés à chaque itération et par un certain degré d'appartenance variant entre 0 et 1 [60, 63, 64].

Par contre, l'algorithme *K*-means permet de fournir une partition fixe de l'ensemble de données en optimisant une fonction coût dont la partition finale est dépendante du choix des centres initiaux. Les méthodes de clustering dynamique (nuées dynamique) [65] est une généralisation de la méthode des centres-mobiles ou en supposant que la représentation d'une classe n'est plus restreinte à son centre de gravité, mais peut apparaître sous n'importe quelle forme (individus, histogrammes, intervalles vectoriels, lois de probabilité, etc.). Dans l'algorithme *K*-Medoids. Dans l'algorithme *K*-Medoid [66], le représentant d'une classe est un individu de cette classe, appelé un medoid. Les médoïdes sont attribués au hasard au début de l'algorithme, puis chaque médoïde est échangé avec un individu de sa classe jusqu'à ce que celui avec la plus petite distance à tous les autres individus soit trouvé, qui deviendra le médoïde final. Puisqu'aucun calcul de centre de gravité n'est requis, cet algorithme a l'avantage de pouvoir utiliser des distances arbitraires ; de plus, il est plus résistant aux valeurs aberrantes que les centres mobiles, mais sa complexité algorithmique est plus élevée [60].

Le modèle neuronal prouvant ses capacités de classifier et visualiser les données multidimensionnelles dans différents domaines et l'un des utiles outils connexionnistes est la carte auto-organisatrice de Kohonen (Self Organizing Map : SOM) Qui est un type de réseau de neurones artificiels constitué d'un ensemble de neurones arrangés suivant une

grille à faible dimension. Chaque neurone associe un vecteur prototype qui appartient à l'espace des observations. L'apprentissage du réseau se fait incrémentalement ou différemment (en mode batch), il se fait d'une façon non supervisée, en vue de projeter les observations sur la carte. Concernant la version incrémentale, chaque itération du processus d'apprentissage présente aléatoirement une observation au réseau, et les vecteurs prototypes des neurones sont mis à jour afin de les rapprocher de cette observation [60]. Cependant, en ce qui concerne le mode différé, à chaque itération, toutes les observations sont présentées au réseau et les vecteurs prototypes des neurones sont mis à jour. Pour finir l'apprentissage, une observation sera affectée au neurone dont le vecteur prototype en est le plus proche. On peut classifier les données si on suppose que les observations affectées au même neurone appartiennent à la même classe ; c.-à-d. que le nombre de neurones correspond au nombre de classes et que deux neurones voisins sur la carte représenteront des classes voisines dans l'espace des observations.

La définition des cartes auto-organisatrices et des autres méthodes de classification est faite initialement pour des données quantitatives univaluées. Or que la présentation des données issues des expériences réelles est sous forme de données qualitatives, d'ensembles de valeurs quantitatives ou qualitatives ou bien même sous forme d'intervalles ou histogrammes. On parle de données symboliques. Qu'on peut les tirer directement des expériences, ainsi de l'agrégation d'un grand jeu de données à valeurs univaluées et cela afin de réduire la taille en vue de faciliter l'analyse des données qu'il contient.

2.2. Méthodes de sélection des caractéristiques et de classification automatique

Il est trop important de sélectionner des caractéristiques pour de nombreuses applications d'apprentissage automatique et d'exploration de données. En particulier, de nombreux algorithmes de régression ou de classification fonctionnent particulièrement mal face à des données de grande dimension en raison de la soi-disant malédiction de la dimensionnalité. En réduisant la dimensionnalité d'un jeu de données tout en préservant les caractéristiques d'origine (par opposition aux techniques de projection), la sélection des caractéristiques assure l'efficacité et la simple interprétation des modèles.

Ces méthodes pour filtrage reposent sur des critères statistiques pour évaluer la corrélation d'un ensemble de caractéristiques et sont souvent utilisées dans la pratique ; cela est principalement dû au fait qu'elles sont peu coûteuses en termes de calcul et indépendantes de tout modèle prédictif, par rapport aux autres types d'approches comme

wrapper, qui optimisent directement les avantages d'un modèle prédictif spécifique. En effet, ces méthodes de filtrage peuvent être utilisées avant la construction de tout modèle de prédiction.

Réduire la dimensionnalité avant toute analyse de données est essentiel. Le critère général de réduction de la dimensionnalité est de vouloir conserver la plupart des informations pertinentes dans les données d'origine selon un critère optimal. Parmi les méthodes les plus utilisées dans les sujets de classification automatique et de reconnaissance de formes, on citera trois méthodes linéaires : l'analyse en composantes principales (ACP), la carte auto-organisatrice (SOM : self-organizing-map) et la classification hiérarchique ascendante (CAH). Ces méthodes recherchent une correspondance entre l'espace des caractéristiques d'origine et celui des caractéristiques de faible dimension.

Dans certaines applications, il peut être souhaitable de sélectionner un sous-ensemble des fonctions d'origine, plutôt que de trouver un mappage qui utilise toutes les fonctions d'origine. L'avantage de trouver ce sous-ensemble de caractéristiques peut être de réduire le coût de calcul des caractéristiques inutiles, Économiser sur le coût des capteurs (dans les systèmes de mesure physique) et exclure les fonctionnalités bruyantes, tout en préservant leurs informations avec des fonctionnalités "propres".

2.2.1. Analyse en composantes principales (ACP)

L'Analyse en Composantes Principales (ACP ou PCA en anglais), est une méthode d'analyse des données qui transforme des variables corrélées en de nouvelles variables décorrélées. L'idée générale de fonctionnement de l'ACP est de réduire un groupe de données plein de variables interdépendantes dans un sous-espace de *Composantes* ou axes principaux [67, 68]. On parle d'une approche à la fois géométrique et statistique. Ces nouvelles variables correspondent à des combinaisons linéaires des variables d'origine. La quantité de composantes principales est moindre ou égale au nombre de variables d'origine. L'information contenue dans un jeu de données correspond à la variance ou à l'inertie totale qu'il contient. L'ACP utilise des corrélations pour assurer la description et le résumé de l'information contenue dans des variables. Cette méthode développée de nouveau et formalisée dans les années 1930 par Harold Hotelling a été généralisée parmi les analyses factorielles. En effet, l'ACP réduit la dimensionnalité des données multi-variées en composants principaux (deux ou trois), pouvant être visualisé graphiquement avec le moins

de perte d'informations possible. Cette technique est appliquée dans la biologie, l'économie et plus récemment dans le traitement d'images et que l'on utilise essentiellement pour :

- Décrire et afficher les données ;
- Décorrélérer : les axes de la nouvelle base ne sont plus liés les uns aux autres.
- Les ébruiter, compte tenu que les axes décidés être oubliés sont des axes bruités.
- Réduire la taille du modèle éléments finis (c'est ce qui nous intéresse).

❖ Réduction de dimensionnalité basée sur la sélection des caractéristiques

Analyser en composantes principales veut dire réduire des variables. Cette méthode est utile lorsque vous avez des données sur plusieurs variables (éventuellement un grand nombre de variables) et que vous pensez qu'il y a une certaine redondance dans ces variables parce qu'elles sont liées entre elles, probablement avec la même construction. Pour cela, la réduction des variables observées en un minimum de composantes principales (variables artificielles) est possible, ce qui expliquera l'essentiel de la variance des variables observées.

Lors du calcul de la corrélation entre plusieurs variables, celle-ci est généralement agrégée sous forme d'une matrice de covariance. On parle d'une bonne occasion de revoir la façon dont les matrices de covariance sont interprétées [69].

Techniquement, une composante principale peut être définie comme une combinaison linéaire de variables observées pondérées de manière optimale. Afin de comprendre le sens de cette définition, il est nécessaire de décrire d'abord comment les scores des sujets sur les composantes principales sont calculés.

L'idée est de développer une technique pour résumer les informations fournies par "p" variables quantitatives en détruisant "n" unités (appelées individus) le moins possible. La technique utilise une combinaison linéaire de variables pour réduire la dimensionnalité d'un ensemble de données en trouvant un nouvel ensemble composé d'un petit nombre de facteurs dont la dimensionnalité est inférieure à celle de l'ensemble de variables d'origine. Générer une synthèse de ces informations revient à projeter les points dans un espace de dimension inférieure à « p » (nombre de variables initiales). Cependant, cette réduction doit préserver le plus d'informations possibles. Les axes de ce sous-espace sont appelés « axes factoriels » ou « facteurs. Tout variable "p" porte en elle une partie de l'information d'origine ou une partie de l'inertie et une partie de l'information d'origine redondante avec d'autres variables, qui découle de la corrélation entre les variables. C'est la partie

d'information redondante qui va être regroupée dans le résumé factoriel. Les facteurs sont hiérarchisés de la façon suivante [70] :

- Le 1^{er} axe concentre le max d'information Le premier axe concentre le plus d'informations : c'est l'axe de la plus grande dimension du nuage de points, qui fournit le meilleur résumé dans l'espace unidimensionnel, mais il laisse des résidus d'informations.
- Le 2^{ème} axe concentre la valeur maximale de l'information restante, qui est orthogonale au premier axe et est la meilleure synthèse en deux dimensions. Cependant, il laisse également des résidus.
- Le 3^{ème} axe nécessite encore moins d'informations et est orthogonal aux deux premiers. Et ainsi de suite pour les axes suivants dans la mesure où nous pensons qu'ils sont encore informatifs.

Théoriquement, le nombre de composants est égal au nombre de variables d'origine. Cependant, en pratique, la première direction peut couvrir un pourcentage élevé (80%-90%) de toutes les données brutes et est donc utilisée pour limiter l'espace d'observation [70].

❖ Concepts de base

Généralement, le traitement des données par ACP comprend :

- ✓ Calcule de la moyenne pour chaque vecteur de caractéristiques.
- ✓ Centrer les vecteurs.
- ✓ Former la matrice COV (matrice de covariance).
- ✓ Calcule des valeurs et des vecteurs propres de la matrice COV.
- ✓ Utiliser les premiers vecteurs propres qui correspondent aux plus grandes valeurs propres pour constituer les axes principaux (nouvel espace propre).

L'analyse des données est faite dès la matrice de données de p colonnes et n lignes :

$$X = [X_1, X_2, \dots, X_j, \dots, X_p] = \begin{pmatrix} x_{11} & \dots & x_{1p} \\ \dots & \dots & \dots \\ x_{n1} & \dots & x_{np} \end{pmatrix} \quad (2.1)$$

Chaque variable $x = (x_{11}, \dots, x_{n1})$ a un écart type σ_x et une moyenne \bar{x} .

On utilisant les variables centrées ou bien les variables centrées réduites une fois la matrice de données est définie pour la détermination des axes principaux [71]. La matrice de données centrées est déterminée par [72, 73] :

$$X_c = [X_{c1}, X_{c2}, \dots, X_{cj}, \dots, X_{cp}] = \begin{pmatrix} x_{11} - \bar{x}_1 & \dots & x_{1p} - \bar{x}_p \\ \dots & \dots & \dots \\ x_{n1} - \bar{x}_1 & \dots & x_{np} - \bar{x}_p \end{pmatrix} \text{ avec } \bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (2.2)$$

Elle peut être ainsi réduite :

$$\tilde{X}_c = \begin{pmatrix} \frac{x_{11} - \bar{x}_1}{\sigma_{x_1}} & \dots & \frac{x_{1p} - \bar{x}_p}{\sigma_{x_p}} \\ \dots & \dots & \dots \\ \frac{x_{n1} - \bar{x}_1}{\sigma_{x_1}} & \dots & \frac{x_{np} - \bar{x}_p}{\sigma_{x_p}} \end{pmatrix} \quad (2.3)$$

La matrice COV de p variables $X_1, \dots, X_j, \dots, X_p$ mesurées sur un ensemble de n unités est la matrice à p lignes et p colonnes contenant sur sa diagonale principale les variances des p variables, et ailleurs les covariances de ces variables qui sont données par (2.4) [72] :

$$COV = \frac{1}{n} X_c^t X_c = \begin{bmatrix} \Sigma_{11} & \Sigma_{1p} \\ \Sigma_{p1} & \Sigma_{pp} \end{bmatrix} \quad (2.4)$$

$$\text{où : } \Sigma_{ij=i=j(\text{diagonal})} = \text{Var}(X_j) = \frac{1}{n} \sum (x_{ij} - \bar{x}_j)^2 \quad \text{et } \text{cov}(X_k, X_m) = \frac{1}{n} \sum_{i=1}^n (x_{ik} - \bar{x}_k)(x_{im} - \bar{x}_m)$$

La matrice COV est une matrice carrée, symétrique et réelle. La matrice est définie positive si les p variables ne sont pas linéairement liées. Sa trace est égale à la somme des variances empiriques des p variables.

Si on travaille avec les variables centrées et réduites, on passe du tableau des valeurs centrées vers le tableau des valeurs centrées et réduites de la manière suivante :

$$X_{cr} = AX_c \quad (2.5)$$

A : La matrice diagonale contient sur sa diagonale principale les inverses des écarts-type des variables. Elle est donnée par :

$$A = \text{diag}(\Sigma)^{-\frac{1}{2}} = \begin{bmatrix} \frac{1}{\sqrt{\Sigma_{11}}} & & 0 \\ & \frac{1}{\sqrt{\Sigma_{jj}}} & \\ 0 & & \frac{1}{\sqrt{\Sigma_{pp}}} \end{bmatrix} \quad (2.6)$$

Si on calcule la matrice COV à partir du tableau de données centrées et réduites, on obtient la matrice des corrélations empiriques :

$$R_c = \frac{1}{n} X_{cr}^t X_{cr}, \quad (2.7)$$

Il peut s'exprimer de la façon suivante : chaque terme R_{ckl} est égal à :

$$R_{ckl} = \frac{\Sigma_{kl}}{\sqrt{\Sigma_{kk}\Sigma_{ll}}} \quad \text{avec } 1 \leq k \leq p \text{ et } 1 \leq l \leq p \quad (2.8)$$

À partir de la matrice COV, on va trouver les axes factoriels. On peut aussi travailler sur la matrice de corrélation et trouver de nouveaux axes factoriels. C'est pour cela on calcule les valeurs et les vecteurs propres associés. Les valeurs propres trouvées présentent la quantité d'information récupérée dans l'axe.

On change les anciens axes (anciennes variables X_k) par de nouveaux axes (variables nouvelles Z_k). Les nouvelles variables sont nommées composantes principales ; elles s'expriment comme des combinaisons linéaires des anciennes variables $X_1, X_2, \dots, X_j, \dots, X_p$.

La $k^{\text{ième}}$ composante principale de ce tableau de données est fournie par la transformation linéaire :

$$Z_k = \sum_{j=1}^p V_{kj} X_{cj} = X_c V_k \quad (2.9)$$

avec $V_k^t = [v_{1k}, v_{2k}, \dots, v_{pk}]$ et $Z_k^t = [z_{1k}, z_{2k}, \dots, z_{nk}]$

Le changement de base sur les variables donne le tableau :

$$Z = X_c V \quad (2.10)$$

Où V c'est la matrice de changement de base : $V = (V_1, \dots, V_j, \dots, V_p)$ de dimensions $(p \times p)$.

Ce changement permet de définir les premières nouvelles variables (premières colonnes de Z) qui concentrent l'information (variables significatives) et qui possèdent des propriétés descriptives (absence de corrélation entre variables).

Le vecteur V_1 est sélectionné tel que $\text{var}(Z_1)$ soit maximale, cela revient à deviner V_1 qui va maximiser $V_1^t \text{COV} V_1$. Donc on doit maximiser la variance des observations projetées. Il s'agit d'une problématique d'optimisation sous contrainte. On utilise n'importe quel algorithme afin de déterminer les vecteurs propres pour trouver les valeurs propres de la matrice COV des données :

$$\text{COV} V_i = \lambda V_i \quad (2.11)$$

λ : c'est la valeur propre correspondant.

V_i : c'est le vecteur propre correspondant.

Ces nouvelles variables Z_i sont non corrélées entre elles et de variance maximale. Par construction, ces variances sont décroissantes : $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$. D'une façon générale, on

a :

$$\text{var}[Z_k] = V_k^t \Sigma V_k = \lambda_k \quad (2.12)$$

La $k^{\text{ième}}$ plus grande valeur propre de COV est la variance de la $k^{\text{ième}}$ composante principale.

Comme la matrice variance-covariance est symétrique définie positive, les valeurs propres sont réelles positives et les vecteurs propres peuvent être choisis d'une manière orthonormée. Si la $r^{\text{ième}}$ variance $\text{var}(Z_{r+1})$ est très petite, les variables $Z_{r+1}, Z_{r+2}, \dots, Z_p$ sont quasiment constantes pour tous les individus.

Il est alors naturel de ne conserver que les composantes principales Z_1, Z_2, \dots, Z_r . Dans la pratique, on estime que Z_{r+1} est petite si on a [74] :

$$\frac{(\lambda_1 + \lambda_2 + \dots + \lambda_r)}{(\lambda_1 + \lambda_2 + \dots + \lambda_p)} \approx 90\% \quad (2.13)$$

Généralement, deux à trois composantes principales sont suffisantes, alors, on est passé de p variables corrélées à deux ou trois variables non corrélées qu'on peut représenter à l'aide de graphiques facilement. Finalement l'objectif de l'ACP est donc l'extraction de nouvelles variables classées par ordre d'importance décroissante. On estimant que l'utilisation de nombreux paramètres physico-chimiques descripteurs en entrée d'une chaîne de contrôle et de surveillance de l'eau, ne laisse aucun doute à envisager leur restriction (réduction de la dimensionnalité), à cause des raisons aussi bien techniques qu'économiques.

Par conséquent, afin de trouver le sous-ensemble optimal de p caractéristiques, l'une des deux quantités ci-dessus doit être calculée pour toutes les combinaisons possibles de p caractéristiques. Cette approche est très intéressante car elle satisfait des propriétés bien définies. Son inconvénient est la complexité de la recherche de sous-ensembles. Pour un grand vecteur propre, il est informatiquement impossible de trouver ce sous-ensemble.

Une autre approche proposée dans [75] utilise les composants principaux comme base pour la sélection des caractéristiques. Une valeur absolue élevée du i -ième coefficient d'une composante principale (PC) signifie que l'élément x_i de X est très dominant dans cet axe/PC. En choisissant la variable correspondant au coefficient le plus élevé de chacun des p premiers PC, on peut approximer la même projection que celle calculée par ACP. Cette méthode est une méthode très intuitive et réalisable sur le plan informatique. Cependant, puisqu'il considère chaque PC indépendamment, des variables avec un contenu d'information similaire peuvent être sélectionnées.

Les méthodes proposées dans [76] et [77] sélectionnent des sous-ensembles de taille p en calculant leurs PC projetés dans l'espace dimensionnel le plus petit et en minimisant la métrique à l'aide de l'analyse de Procuste [78]. Cette approche réduit la redondance des informations mais elle est coûteuse en calcul car de nombreuses combinaisons de sous-ensembles sont explorées.

Les deux variables indépendantes ont les vecteurs de poids les plus séparés ; tandis que les deux variables entièrement corrélées ont le même vecteur de poids (jusqu'à ce que le signe change). Pour trouver le meilleur sous-ensemble, nous utilisons la structure de lignes V_i pour trouver d'abord des sous-ensembles de fonctionnalités fortement corrélés, puis nous sélectionnons une fonctionnalité dans chaque sous-ensemble. Les caractéristiques sélectionnées représentent le mieux chaque groupe en termes de forte dispersion dans les

petites dimensions, de reconstruction et d'insensibilité au bruit. L'algorithme peut être résumé dans les cinq étapes suivantes :

- **Etape 1** : Calculer la matrice de covariance de l'échantillon ou utiliser la vraie matrice de covariance si elle est disponible. Dans certains cas, il est préférable d'utiliser la matrice de corrélation au lieu de la matrice de covariance [75]. La matrice de corrélation est définie comme une matrice $n \times n$ dont la i, j 'ième entrée est :

$$\rho_{ij} = \frac{E[x_i x_j]}{E[x_i^2] E[x_j^2]} \quad (2.14)$$

Cette représentation est préférée dans les cas où les caractéristiques ont des variances très différentes les unes des autres, et l'utilisation de la forme régulière de covariance amènera PCA à accorder un poids très important à la caractéristique avec la variance la plus élevée.

- **Etape 2** : Calculer les principales composantes et valeurs propres de la matrice de covariance/corrélation.
- **Etape 3** : Choisir la dimension du sous-espace q et construction de la matrice A_q à partir de A . Cela peut être choisi en décidant de la quantité de variabilité des données que vous souhaitez conserver. La variabilité de la rétention peut être calculée à l'aide de la formule suivante :

$$\text{Variabilité conservée} = \frac{\sum_{i=1}^q \lambda_i}{\sum_{i=1}^n \lambda_i} \cdot 100\% \quad (2.15)$$

- **Etape 4** : Le vecteur de groupe $|V_1|, |V_2|, \dots, |V_n| \in R_q$ en $p \geq q$ clusters utilise l'algorithme K-Means pour diviser. La métrique de distance utilisée pour l'algorithme K-Means est la distance euclidienne. La raison du choix de p plus grand que q dans certains cas est que si la même variabilité prudente que l'ACP est requise, un peu plus de caractéristiques sont nécessaires (généralement 1 à 5 de plus suffisent).
- **Etape 5** : Pour chaque cluster, trouver le vecteur V_i correspondant le plus proche de la moyenne du cluster. Choisir la fonction correspondante x_i comme fonction principale. Cette étape donnera un choix de p caractéristiques. La raison du choix du vecteur le plus proche de la moyenne est double. Cette fonctionnalité peut être considérée comme la fonctionnalité centrale du cluster, qui lui domine et qui contient les informations les moins redondantes sur les autres fonctionnalités du cluster.

Par conséquent, il satisfait les deux propriétés que nous voulons atteindre - une "diffusion" élevée dans un espace de faible dimension et une bonne représentation des données d'origine.

Pour plus de clarté, il convient de noter que les clusters sont des représentations d'entités dans un espace de faible dimension, et non des projections mesurées dans cet espace (comme dans [76]) [79].

2.2.2. Carte auto-organisatrice (self-organizing map –SOM-)

Les cartes auto-organisatrices (SOM) ont été inventées par Kohonen (1984). Inspiré des principes neuronaux du cerveau des mammifères, un graphe auto-organisé est un RNA dont l'apprentissage se déroule de façon non supervisée. Son rôle primordial est de projeter de manière non linéaire des données de grande dimensionnalité dans un espace de faible dimension [60]. La carte auto-organisée (SOM) est un outil d'analyse, de visualisation et d'interprétation de données basé sur les principes de quantification vectorielle et de mesure de similarité vectorielle. Alors que la plupart des procédures SOM peuvent être considérées comme exploratoires, la méthode peut être utilisée pour effectuer une large classe d'opérations telles que l'ajustement de fonction, la prédiction ou l'estimation, le regroupement, la reconnaissance de formes ou la réduction et la classification du bruit. Dans l'analyse SOM, chaque échantillon est traité comme un vecteur à n dimensions (nD) dans l'espace de données défini par ses variables [80].

❖ Concept et principe

Le SOM est un RN à une seule couche avec des cellules placées le long d'une grille à n dimensions. La plupart des applications utilisent des grilles bidimensionnelles et rectangulaires, bien que beaucoup utilisent également des grilles hexagonales et des espaces à une, trois ou plusieurs dimensions. SOM produit une image projetée à faible dimension d'une distribution de données à haute dimension dans laquelle des relations similaires entre des éléments de données sont préservées.

Trois processus sont courants dans la cartographie SOM auto-organisée :

- **Processus compétitif** : Pour chaque vecteur de modèle d'entrée présenté à la carte, tous les neurones calculent la valeur d'une fonction discriminante. Le neurone le plus similaire au vecteur de modèle d'entrée est le gagnant (Best Matching Unit, BMU).

- Processus coopératif : Le neurone gagnant (BMU) trouve la localisation spatiale du voisinage topologique des neurones excitateurs. Les neurones de ce voisinage peuvent alors coopérer.
- Adaptation synaptique : Un neurone qui offre une excitation peut modifier la valeur de sa fonction discriminante par rapport au vecteur de modèle d'entrée présenté par le processus de réglage du poids [81].

❖ Topologies courantes

Les topologies SOM peuvent être unidimensionnelles, bidimensionnelles (les plus courantes) ou même tridimensionnelles. Les deux grilles 2D les plus couramment utilisées dans SOM sont la grille rectangulaire et la grille hexagonale. La topologie 3D peut être cylindrique ou annulaire. Des grilles unidimensionnelles (linéaires) et bidimensionnelles sont illustrées à la figure 2.2 et les SOM correspondants sont sur les figures 2.3 a et b [81].




Fig. 2.2. Grilles et voisinages de neurones les plus courants.




Fig. 2.3, (a). Réseau SOM 1D, **(b).** Réseau SOM 2D.

Il s'agit d'une classification à 2 étapes : premièrement, une projection des données sur une carte formée d'un grand nombre de neurones ($\approx 5\sqrt{n}$, par exemple) et deuxièmement une classification des prototypes où chaque observation appartiendra à la classe du vecteur prototype de son neurone vainqueur (figure 2.4) [82]




Fig. 2.4. Cartes auto-organisatrices pour la classification en deux étapes [60].

❖ Algorithme

Un SOM est un réseau neuronal formé pour générer une représentation discrétisée bidimensionnelle de l'espace d'entrée d'échantillons de formation, appelée carte. Il s'agit exactement de la cartographie non linéaire, ordonnée et fluide de données d'entrée dimensionnelles à des éléments réguliers à faible dimension. En raison de leur capacité à convertir des relations statistiques non linéaires entre des données de grande dimension en leurs relations géométriques simples de points d'image sur une grille bidimensionnelle régulière de nœuds, les graphiques SOM peuvent être utilisés pour la classification et la visualisation des données.

Contrairement à de nombreux autres types de NN, SOM ne nécessite pas de sortie cible spécifiée. Au lieu de cela, lorsque les poids des nœuds correspondent au vecteur d'entrée, cette zone du réseau est sélectivement optimisée pour être plus proche des données de la classe à laquelle appartient le vecteur d'entrée. A partir d'une distribution initiale de poids aléatoires, après de nombreuses itérations, le SOM s'installe finalement dans une carte de régions stables. Chaque région est en fait un classificateur d'entités.

L'algorithme d'apprentissage standard de Kohonen est un processus de formation non supervisé. Il génère des quantificateurs vectoriels en mettant à jour à plusieurs reprises le prototype d'unité de classe. Après initialisation : prototype ($W_i(t)$), taux d'apprentissage ($lr(t)$) et voisinage ($N_i(t)$), tous les modèles sont présentés au réseau SOM. Pour chaque motif X_p , calculer la distance C , $d_i = |W_i(t) - x_p|$ au prototype d'unité de classe et choisir

l'unité de classe gagnante j . Ensuite, mettre à jour le prototype de l'unité de classe j et les unités de classe dans le voisinage $N_j(t)$.

Les étapes de l'algorithme de Kohonen sont :

1- Initialiser le réseau : nombre d'unités de classe C , prototypes W_i , taux d'apprentissage $lr(t)$, voisinages $N_i(t), i = 1 \dots C$ nombre maximum d'époques T_{max} et précision ϵ .

2- Présenter un nouveau modèle X_p au réseau.

3- Déterminer l'unité de classe gagnante j , la plus proche du motif

$$d_j = \min(d_i) = \min(W_i(t) - x_p), i = 1 \dots C \quad (1)$$

4- Mettre à jour les prototypes de l'unité de classe j et des unités de classe gagnantes à l'intérieur du quartier $N_j(t) : w_i(t+1) = w_i(t) + lr(t) | x_p - w_i(t) | i \in N_j(t)$ avec $lr(t) = \alpha(t) \cdot h_{ci}(t)$.

5- Mettre à jour le taux d'apprentissage $lr(t+1)$ et les voisinages $N_i(t+1), i = 1 \dots C$.

En règle générale, la fonction de voisinage est une fonction unimodale qui est symétrique par rapport à l'emplacement du gagnant et diminue de manière monotone avec l'augmentation de la distance du gagnant [83].

• *la fonction gaussienne* : est la fonction la plus flexible et plus commune illustrée dans la figure 2.4 et définie ci-après :

$$H_{ci}(t) = \exp\left(\frac{-\|r_c - r_i\|^2}{2 \cdot \delta(t)^2}\right) \quad (2.16)$$

Dans cette expression, $\|r_c - r_i\|^2$ représente la distance entre les cellules c et i dans l'espace de sortie, où r_i est le vecteur de position 2D de la cellule i dans la grille. Le paramètre variant dans le temps δ guide la réduction des noyaux de voisinage pendant l'apprentissage [83]. En utilisant une telle fonction de voisinage (figure 2.5), l'amplitude de l'ajustement est graduée en fonction de la distance du neurone gagnant, qui se réserve la plus grande amplitude. Le résultat de cet apprentissage non supervisé est une projection non linéaire de toutes les observations sur la carte. Chaque observation est accordée à son neurone gagnant. En plus de la tâche de quantification, cette projection assure également la topologie des données en raison d'utilisation d'une fonction de voisinage. Deux neurones adjacents sur la carte montreront des observations proches dans l'espace de données.




Fig. 2.5. Fonction de voisinage gaussienne.

• *Le chapeau mexicain* : La fonction de voisinage donnée par Kohonen est directement inspirée des modèles biologiques, dans lesquels une cellule active sa voisine la plus proche et supprime sa voisine la plus éloignée. Dans le cas du réseau, le vecteur prototype de la cellule la plus proche de *bmu* est déplacée vers l'entrée proportionnellement à $a(t)$, tandis que le vecteur prototype de la cellule la plus éloignée est repoussé. La fonction utilisée dans cet exemple est la fonction du chapeau mexicain (figure 2.6) :

$$h_g(w_{ij}, w_{mn}, r) = e^{-\frac{1}{2} \left(\frac{\sqrt{(i-n)^2 + (j-m)^2}}{r} \right)^2}$$

Fig. 2.6. Fonction de chapeau mexicain

6- Répéter les étapes 2 à 5 jusqu'à ce que le changement de prototype dans deux époques consécutives soit inférieur à ε , ou que le nombre d'époques maximum T_{\max} soit atteint.

Pour déterminer la meilleure unité de correspondance, une approche consiste à parcourir tous les nœuds et à calculer la distance euclidienne entre le vecteur de poids de chaque nœud et le vecteur d'entrée actuel. Le nœud dont le vecteur de poids est le plus proche du vecteur d'entrée est marqué comme la meilleure unité correspondante.

Un problème majeur avec SOM est d'obtenir les données correctes. Malheureusement, vous devez définir une valeur pour chaque dimension de chaque membre de l'échantillon pour générer la carte. Il est parfois difficile d'obtenir toutes ces données, il s'agit donc

d'une caractéristique limitative de l'utilisation de SOM, souvent appelée données manquantes.

Un autre problème est que chaque SOM est différent et que différentes similitudes sont trouvées entre les vecteurs échantillons. SOM organise les données d'échantillon de sorte que dans le produit final, les échantillons soient souvent entourés d'échantillons similaires. Cependant, des échantillons similaires ne sont pas toujours proches les uns des autres. Si vous avez beaucoup de nuances de couleur, vous n'obtiendrez pas toujours un grand groupe où tous les violets sont dans ce groupe, parfois les groupes se diviseront et il y aura deux ensembles de violets. En utilisant les couleurs, nous pouvons voir que les deux groupes sont en fait similaires, juste séparés, mais pour la plupart des données, les deux groupes semblent totalement indépendants. Il faut donc construire beaucoup de cartes pour obtenir une bonne carte finale.

Le dernier problème majeur avec SOM est qu'il est très gourmand en calcul, ce qui est un inconvénient majeur car à mesure que la dimensionnalité des données augmente, les techniques de visualisation de réduction de dimensionnalité deviennent plus importantes, mais malheureusement, le temps pour les calculer augmente également. Pour calculer cette carte de similarité en noir et blanc, plus vous utilisez de voisins pour calculer les distances, meilleure sera la carte de similarité, mais le nombre de distances que l'algorithme doit calculer augmente de façon exponentielle.

Les avantages des SOM sont : Faciles à comprendre, idéal pour les problèmes de classification et d'évaluation de leur propre qualité, les utilisateurs peuvent calculer intuitivement la qualité de la carte et la force de similarité entre les objets. Malgré tous ces aspects, il est idéal pour les applications de classification [84].

❖ Mesures de qualité

Pour qu'une carte auto-organisée soit un modèle précis, elle doit s'adapter aux données tout en préservant la topologie et le voisinage des données d'entrée. La topologie est la relation spatiale entre les points de données où les voisinages sont des groupes de points de données qui se trouvent dans la même région de l'espace d'entrée. Un modèle utilisant les données décrira les relations sous-jacentes sans bruit de modélisation.

Les mesures de qualité pour cette analyse sont choisies en fonction de leur pertinence et de leur popularité. La méthode traditionnelle proposée par Kohonen calcule l'erreur de quantification en additionnant les distances entre les nœuds et les points de données. Les

erreurs topologiques expliquent la préservation par le SOM des caractéristiques topologiques locales dans l'espace de sortie de faible dimension. La fonction topologique tente d'utiliser un "champ récepteur induit" pour mesurer la préservation topologique et rapporter une fonction de décalage quantifié. La convergence basée sur la population est une mesure basée sur l'analyse statistique de cartes. Ces mesures sont détaillées dans les chapitres précédents.

Notez que certaines autres mesures de la qualité n'ont pas été incluses dans cette étude. Le produit topologique est la somme des distorsions dans les espaces d'entrée et de sortie de chaque neurone et est utilisé pour quantifier l'adéquation de la taille de la carte. La distorsion utilise la fonction de coût pour calculer la valeur d'erreur de la carte, mais pas pour l'algorithme SOM général. Polani mène une enquête détaillée sur diverses autres méthodes plus obscures [85].

- **Erreur de quantification**

Un autre paramètre SOM utile enregistré pour chaque échantillon d'entrée est l'erreur de quantification (QE). Cette erreur est essentiellement une mesure de la distance entre un échantillon et son vecteur de nœud. Les échantillons avec des erreurs de quantification élevées représentent des valeurs aberrantes dans l'ensemble de données. Ces échantillons ont tendance à être des valeurs aberrantes par rapport à la plupart des échantillons. Ces échantillons QE élevés peuvent également représenter les bords ou les limites de l'ensemble de données, ce qui, en géologie, a des implications pour les contacts lithologiques, etc [80].

Kohonen recommande QE comme mesure de qualité de base pour évaluer les cartes auto-organisées. Calculez la valeur de la carte à l'aide de (2.17), où n est le nombre de points de données dans les données d'apprentissage et $\phi : D \rightarrow M$ est le mappage de l'espace d'entrée D vers le M .

$$QE(M) = \frac{1}{n} \sum_{i=1}^n \|\phi(x_i - x_i)\| \quad (2.17)$$

Notez que les valeurs rapportées sont à la même échelle que les données d'entrée, et ne doivent donc être utilisées que pour comparer les cartes les unes par rapport aux autres, et non comme une évaluation indépendante de la qualité.

Une limitation bien étudiée du QE est qu'il converge avec l'augmentation de la taille de la carte ou du nombre d'itérations de formation. Yin et Allison ont montré qu'à mesure que

la dimensionnalité et/ou le nombre d'itérations du mappage augmente, l'erreur du mappage tendra vers zéro.

De plus, cette approche ne considère que la relation entre les nœuds et les neurones auxquels ils sont mappés, et non l'organisation relative des neurones. Cela signifie que QE n'évalue que la structure locale des données, c'est-à-dire qu'il ne peut pas détecter les problèmes de diversité de la carte (c'est-à-dire le gauchissement, le pliage) [85].

- **Erreur topographique**

L'un des principaux objectifs de l'algorithme SOM est de préserver les caractéristiques topologiques de l'espace d'entrée dans l'espace de sortie de faible dimension. L'erreur de terrain (TE) est une mesure de la façon dont la structure spatiale d'entrée est modélisée par la carte. Plus précisément, il évalue les discontinuités locales de la carte.

TE est calculé en trouvant les meilleurs neurones correspondants et les suivants dans le graphique pour chaque entrée, puis en évaluant l'emplacement. Si les nœuds sont côte à côte, on dit que la topologie a été réservée pour cette entrée. Sinon, il sera traité comme une erreur.

Le nombre total d'erreurs divisé par le nombre total de points de données donne l'erreur de terrain de la carte. Ceci est résumé dans (2.18), où $\mu(x)$ renvoie la meilleure unité de correspondance pour le point de données x et $\mu'(x)$ renvoie la deuxième meilleure unité de correspondance.

$$TE(M) = \frac{1}{n} \sum_{i=1}^n t(x_i) \quad (2.18)$$

$$t(x) = \begin{cases} 0 & \text{if } \mu(x) \text{ et } \mu'(x) \text{ sont voisins} \\ 1 & \text{autrement} \end{cases}$$

Notez que cette métrique évalue uniquement la qualité du mappage d'un seul point de données à un nœud et ne tient pas compte des distorsions plus importantes dans le collecteur [85].

- ❖ **La matrice de distance unifiée (matrice U)**

La représentation "matrice de distance uniforme" (matrice U) de "carte" représente la proximité entre les nœuds adjacents sur la carte, généralement exprimée en distance euclidienne. Une échelle de température de couleur est utilisée pour que les couleurs plus

froides (bleu) séparent les nœuds adjacents les plus proches (similitude), tandis que les couleurs plus chaudes représentent une plus grande séparation euclidienne (différence).

À des fins d'affichage, des nœuds "virtuels" alternés ont été ajoutés à la matrice U, qui sont colorés en fonction de la distance entre les nœuds adjacents ; tandis que les nœuds représentant de vrais vecteurs sont colorés en fonction de la moyenne des distances à leurs voisins. Cette représentation donne une analogie topographique, car il existe des vallées avec des nœuds similaires (bleus) séparés par des murs de nœuds colorés représentant des limites de classe ou des températures plus élevées pour des échantillons appartenant à différents groupements. La figure 2.7 montre une matrice U typique avec des hexagones blancs aux nœuds qui représentent réellement les échantillons d'entrée ; la taille des hexagones est proportionnelle au nombre d'échantillons d'entrée que chaque nœud représente [80].




Fig. 2.7. La représentation de la matrice en U avec des hexagones blancs dimensionnés proportionnellement au nombre d'échantillons tombant sur chaque nœud.

❖ Applications

La méthode SOM est avant tout un moyen de représenter des données multidimensionnelles qui peut être comparée à d'autres méthodes de représentation comme l'ACP. Cette technique peut également définir une fonction analytique linéaire $F : \mathbb{R}^n \rightarrow \mathbb{R}^p$, permettant de projeter tout nouveau point. D'autres méthodes de projection, telles que Sammon ou la projection triangulaire, sont non linéaires mais ne peuvent représenter que des ensembles d'apprentissage limités car elles ne remplissent pas la fonction F . En revanche, la méthode SOM définit une fonction F non linéaire dont le nouvel espace de représentation est discret.

- **Classification** : Vercauteren [86] a utilisé SOM pour classer les tumeurs cérébrales dans une grande base de données. De même, on retrouve l'article d'Elo et al. [87] qui ont utilisé la SOM pour classer l'électroencéphalographie épileptique (EEG). Ils ont prétraité les signaux EEG via des étapes de segmentation et d'extraction de caractéristiques. D'autre part, Simula et Visa [88] effectuent la classification et la segmentation des textures.
- **Discrimination** : La 1ère application de SOM sur des données réelles et complexes a été la machine à écrire vocale de Kohonen [89]. Diverses applications du traitement du langage et de la parole ont suivi : reconnaissance statistique de formes (parole) [88,89] et sémantique. Koyzumi [90] a appliqué un mélange de chaînes SOM et Markov pour la reconnaissance des phonèmes. Scholtes [91] utilise deux cartes, la première pour extraire le contexte et la seconde pour les caractéristiques du langage. Dans le domaine de la robotique, le travail est largement axé sur l'apprentissage. Ritter et al. Le premier test [92] est proposé en dimension 2 pour apprendre la position du bras en visualisant la position du bras à l'aide d'une caméra. Ce travail a été étendu dans l'espace 3D avec des cartes à architecture 3D [93]. Kohonen et al. Un détecteur de signal discret est proposé [94]. Il est bon de citer le très excellent travail de Ritter, Martinetz et Schulten, qui rend compte de tous ces résultats [95].
- **Analyse exploratoire des données** : l'industrie ne s'est intéressée au SOM qu'au tournant des années 1990 après des expérimentations fructueuses dans le domaine scientifique. La plupart des applications sont liées au suivi des procédés de fabrication : Kasslin et al. La possibilité de SOM pour une telle surveillance a été décrite [96]. Tryba et Goser recommandent de suivre une procédure chimique [97, 98]. Il existe également des applications dans le domaine des télécommunications [99, 100]. Badland et al. [101] ont proposé une méthode d'adaptation de carte topologique pour lisser les nuages de points.
- **Sélection des caractéristiques** : La sélection des fonctionnalités pour la réduction de la dimensionnalité est une étape couramment utilisée dans l'apprentissage automatique pour garantir de bonnes décisions, de bonnes performances et un niveau élevé de capacité de classification du modèle ajusté. Dans cette étude, nous utilisons la méthode SOM comme première analyse pour sélectionner un sous-ensemble de variables corrélées et non corrélées afin de déterminer les données d'entrée pour le modèle de classificateur proposé. Dans l'apprentissage automatique, la réduction de l'espace des fonctionnalités est souvent effectuée en créant un sous-ensemble de nouvelles dimensions à l'aide de la méthode SOM.

- Application du SOM à la validation des données

Dans les parties précédentes, nous avons vu en détail l'algorithme SOM et ses différentes applications. Nous allons maintenant voir comment utiliser ce modèle pour définir une méthode de validation de données multi-paramètres. En fait, les cartes topologiques de Kohonen ne sont pas seulement un moyen de visualiser et de classer des données de grande dimension, mais également de détecter des données atypiques en contrôlant la distance entre chaque vecteur d'entrée x et bmu . Cette technique peut être vue comme une variante du concept de rejet à distance introduit par Dubuisson et Masson. [9, 102]

❖ Principe de la méthode

Admettons donc que nous ayons un ensemble de N prototypes ou vecteurs de référence $\{w_1, \dots, w_N\}$. Chaque prototype w_k représente la classe vectorielle w_k de x . L'espace de référence est donc divisé en N classes.

Nous définissons "l'activation" du prototype i pour le vecteur d'entrée x à l'aide d'un noyau gaussien :

$$k_i(x) = \exp\left(\frac{-1}{2\sigma_i^2} \|x - w_i\|^2\right) \quad (2.19)$$

Où σ_i^2 est un paramètre qui définit la zone d'influence du prototype i . σ_i^2 peut être défini comme la moyenne empirique des variances des n vecteurs d'entrée du prototype d'activation i . Plus le σ_i^2 est grand, plus la plage d'influence de w_i est grande, et donc plus l'activation $K_i(x)$ est proche de 1.

Un vecteur x est considéré comme invalide si l'activation $K_b(x)$ du prototype le plus proche w_b est inférieure à un certain seuil α . Le diagramme schématique du mécanisme de vérification des données 3D est illustré à la Figure 2.8.

Cette méthode de rejet des données atypiques permet le processus de détection de nouveaux échantillons qui peuvent devoir être inclus en l'ensemble d'apprentissage. Le rejet peut être dû à un défaut du capteur ou simplement à un terme de l'ensemble d'apprentissage. Il est donc nécessaire de stocker ces vecteurs rejetés pour permettre une interprétation ultérieure par l'utilisateur et éventuellement un réapprentissage du système. [9]




Fig. 2.8. Illustration du mécanisme de validation des données 3D.

Pour bien déterminer quelles composantes invalides du vecteur x sont, la contribution de chaque composante est examinée séparément. Puis on calcule la distance de chaque composante j du vecteur x à la composante la plus proche du prototype $|x_j - w_{bj}|$. La composante avec la plus grande distance est alors déconnectée et un nouveau prototype gagnant est recalculé en utilisant uniquement les composantes valides du vecteur x .

Le processus de détection peut recevoir une interprétation probabiliste, en supposant que le vecteur d'entrée x suit un mélange de distributions normales (ou classes) avec une moyenne w_i et une variance $\sigma_i^2 I$ (I désigne la matrice d'identité). L'activation du prototype i le plus proche via le vecteur d'entrée x peut être considérée comme une approximation (à l'intérieur d'une constante) de la densité de probabilité conditionnelle de la classe i étant donné x . [9]

- Définition du seuil α

Nous avons une collection de vecteurs n_A de l'ensemble d'apprentissage. Nous considérerons 1 % de ces données comme invalides ou anormales. Par conséquent, nous calculons l'activation $K_b(x)$ du prototype le plus proche pour ces n vecteurs. Par conséquent, nous pensons que 1 % de l'activation des données dans l'ensemble d'apprentissage est trop faible pour être considéré comme valide. Nous trions les données par ordre croissant d'activation. Ainsi, le seuil α correspond à une activation $K_b(x)$ de rang $n/100$. [9]

- Application au traitement de données manquantes et invalides

Dans la section précédente, nous avons présenté l'application de l'algorithme SOM à la détection des données aberrantes. Nous allons maintenant découvrir comment utiliser ce modèle pour traiter les données invalides ou manquantes. [9]

- Principe de la méthode

Si le prototype fournit une bonne représentation des données, on peut espérer utiliser d'autres coordonnées pour reconstituer les valeurs manquantes des vecteurs proches du prototype donné.

Soit x un nouveau vecteur composé de deux parties x^o et x^m , contenant respectivement les variables observées et manquantes. Le but est de reconstruire x^m en utilisant les informations fournies par la carte topologique de Kohonen. Intuitivement, notre méthode proposée repose sur la similarité entre ce nouveau vecteur $x = (x^o, x^m)$ et le vecteur de référence ou prototype w_k . Soient X^o et X^m des sous-espaces de X , restreints aux variables observées et manquantes de x et, w_k^o et w_k^m les projections de w_k sur ces sous-espaces. Plus x^o est proche de w_k au sens de l'activation défini par l'équation (2.20), plus grande est la probabilité que x^m soit « plus proche » de w_k^m .

$$k_i(x^o) = \exp\left(\frac{-1}{2\sigma_i^2} \|x^o - w_i^o\|^2\right) \quad (2.20)$$

Ci-dessous, on notera $O(x) \subset \{1, \dots, r\}$ et $M(x)$, l'ensemble d'indices des composantes observées et manquantes. [9]

- Estimation des données manquantes

Pour l'estimation ou la reconstruction des données manquantes x^m , nous avons considéré deux approches.

Dans un premier temps, nous avons utilisé une méthode simple d'estimation des données manquantes par les valeurs des composantes correspondantes du prototype gagnant w_b :

$$\forall l \in M(x), \hat{x}_l = w_{bl} \quad (2.21)$$

La méthode est très sensible aux changements de prototype entre deux vecteurs consécutifs x . Pour résoudre ce problème, nous considérons une autre approche très similaire, qui prend en compte l'influence des k prototypes les plus proches. Chaque composante manquante de x^m est estimée par la combinaison des k composantes correspondantes les plus proches du prototype :

$$V1 \in M(x), \hat{x}_l = \frac{\sum_{i=0}^k k_i(x^0) \cdot w_{il}}{\sum_{i=0}^k k_i(x^0)} \quad (2.22)$$

Si nous nous plaçons dans le contexte de la probabilité, nous pouvons considérer le calcul de cette composante manquante de x^m comme une légère modification de la méthode de la fonction de base radiale avec un noyau gaussien (Fig. 2.9). [9]




Fig. 2.9. Illustration du mécanisme d'estimation des données manquantes 2D. [9]

2.2.3. Classification hiérarchique ascendante ou clustering hiérarchique

La base du clustering hiérarchique est de créer une hiérarchie de clusters. A la racine de l'arbre est associé un cluster unique contenant tous les objets de la base, puis plus bas dans le cluster plus le cluster est spécifique à un groupe particulier d'objets considérés comme similaires. La figure 2.10 montre une telle hiérarchie.

Pour former une telle hiérarchie de clusters, il existe deux approches principales :

- Méthode ascendante, en commençant par autant de clusters qu'il y a d'objets initiaux dans la base de données, puis en fusionnant les clusters considérés comme les plus similaires dans l'ordre jusqu'à ce que tous les objets soient fusionnés en un seul cluster, stocké à la racine de la hiérarchie résultante ;
- La méthode descendante, en revanche, commence par un seul cluster contenant tous les objets de la base, puis divise les clusters afin de rendre les clusters résultants aussi différents que possible, jusqu'à ce que vous atteigniez une base de données de clusters avec autant de feuilles de la hiérarchie car il y a des objets dans l'objet.

Ainsi, on retrouve à ce niveau la distinction classique entre généralisation et apprentissage spécialisé : les approches ascendantes commencent par des solutions totalement spécifiques aux données puis se généralisent à chaque étape, tandis que les approches

descendantes commencent par des solutions totalement génériques puis se spécialisent à chaque étape.




Fig. 2.10. Clustering hiérarchique.

Étant donné une mesure de distance entre deux clusters, la fusion suivante effectuée pour la méthode d'ascension impliquera les deux clusters les plus proches, tandis que la division suivante effectuée pour la méthode de descente impliquera les deux clusters les plus éloignés. Il existe trois alternatives principales pour définir la distance entre deux clusters :

- La méthode *single-link* : La similarité de deux clusters est mesurée par la similarité maximale entre les documents de chaque cluster. Autrement dit, la similarité entre les deux clusters S_r et S_t est donnée par :

$$\text{sim single-link } (S_r, S_t) = \min_{di \in S_r, dj \in S_t} \{\cos(di, dj)\} \quad (2.23)$$

- La méthode *complete-link* : utilise la similarité minimale entre une paire de documents pour mesurer la même similarité [103]. C'est-à-dire,

$$\text{sim complete-link } (S_r, S_t) = \max_{di \in S_r, dj \in S_t} \{\cos(di, dj)\} \quad (2.24)$$

- La méthode *average-link* : En général, les méthodes à lien unique et à lien complet ne fonctionnent pas bien car leurs décisions sont basées sur une quantité limitée d'informations (lien unique) ou elles supposent que tous les documents d'un groupe sont très similaires les uns aux autres. Autre (méthode du lien complet).

Le schéma UPGMA (également connu sous le nom de moyenne de groupe) surmonte ces problèmes en mesurant la similarité de deux clusters comme la moyenne des similarités par paires de documents dans chaque cluster [104, 105] :

$$\text{sim}_{\text{UPGMA}}(Sr, St) = \frac{1}{n_i n_j} \sum_{di \in Sr, dj \in St} \cos(di, dj) = \frac{D_i D_j}{n_i n_j} \quad (2.25)$$

Ensuite, une fois la hiérarchie formée, une étape facultative peut être ajoutée pour affiner les résultats fournis à l'utilisateur. Se pose alors le problème de la détermination du niveau de division le plus approprié à appliquer dans l'arbre afin d'obtenir les données de la manière la plus pertinente possible. Pour ce faire, on peut demander à l'utilisateur de préciser le nombre de clusters attendus et utiliser différentes mesures de la qualité interne des différentes partitions possibles pour choisir la plus pertinente où l'utilisateur peut être invité à spécifier un seuil pour la cohésion interne ou l'isolation externe minimale du cluster.

Bien que largement utilisée, cette approche devient difficile à utiliser face à de grandes bases de données, car sa complexité est quadratique, en fonction du nombre d'objets dans la base de données, car toutes les paires d'objets possibles doivent être calculées entre la distance. De plus, cette méthode ne peut jamais annuler ce qu'elle a déjà fait auparavant. Elle ne peut donc pas être utilisée de manière incrémentielle. Enfin, Elle inclut le phénomène des effets de chaîne, c'est-à-dire que des clusters proches mais distincts peuvent être fusionnés s'il existe une chaîne d'objets les reliant. Le tableau 2.1 résume les différentes caractéristiques de cette approche.

Tableau. 2.1. Caractéristiques associées au clustering hiérarchique.

caractéristique	valeur
Connaissance à priori	Nombre de clusters ou seuils
Présentation des résultats	Hiérarchie
Complexité	$O(M \times N^2)$
Déterministe	Oui
Incrémentale	Non
Any-time	Non
Hard	Oui
Prise en compte du contexte	Non
Tolérance au bruit	Non
Tolérance à l'effet de chaîne	Non
Tolérance aux clusters de tailles variées	Oui
Tolérance aux clusters de densités variées	Oui
Tolérance aux clusters de forme quelconque	Oui
Tolérance aux clusters concentriques	Oui

Dendrogramme : Un dendrogramme ou arbre de classification ou de partition est une représentation graphique couramment utilisé pour illustrer différents groupes définis par une classification hiérarchique.

Tableau. 2.2. Comparaison entre les méthodes d'analyses de données utilisées.

	Analyse en composantes principales ACP.	Carte auto-organisatrice SOM.	Classification ascendante hiérarchique CAH.
Avantages	<ul style="list-style-type: none"> ❖ Simplicité mathématique : Le seul véritable outil mathématique utilisé en PCA est le calcul des valeurs propres/vecteurs propres de la matrice. ❖ Simplicité des résultats : L'analyse en composantes principales peut comprendre la plupart de ses résultats en un coup d'œil grâce aux graphiques qu'elle fournit. ❖ Puissance : La méthode fournit à la fois un résumé et une vue complète de la relation entre les variables en quelques opérations seulement. ❖ Flexibilité : Cette méthode est très flexible car elle fonctionne pour un ensemble de données de contenu de n'importe quelle taille. 	<ul style="list-style-type: none"> ❖ Facile à comprendre, elle est très adaptée à la classification des problèmes et à l'évaluation de sa propre qualité. Les utilisateurs peuvent calculer intuitivement la qualité de la carte et la similarité entre les objets. Malgré tous ces aspects, SOM est idéale pour les applications de classification. ❖ Une technique de réduction de dimensionnalité non linéaire. ❖ Avec autant de sorties graphiques, les résultats sont faciles à comprendre et à interpréter. 	<ul style="list-style-type: none"> ❖ On travaille par les dissimilarités entre les objets que l'on veut regrouper. Par conséquent, nous pouvons choisir un type de dissimilarité qui convient au sujet réfléchi et à la nature des données. ❖ L'un des résultats est le dendrogramme, qui permet de visualiser le regroupement progressif des données. On peut alors se faire une idée d'un nombre adéquat de classes dans lesquelles les données peuvent être regroupées.
Inconvénients	<ul style="list-style-type: none"> ❖ L'ACP est très sensible aux valeurs aberrantes. 	<ul style="list-style-type: none"> ❖ La topologie de la carte est toujours indiquée à priori. ❖ Sensible aux valeurs extrêmes. 	<ul style="list-style-type: none"> ❖ CAH ne peut à priori choisir un nombre défini de classes. ❖ Toutes les approches pour calculer la similarité entre clusters ont leurs propres inconvénients.

Conclusion

Le thème de ce chapitre est d'attirer l'attention sur les principes fondamentaux des méthodes et techniques d'analyse de données appliquées à la sélection des caractéristiques à base d'apprentissage automatique pour la classification et à la régression. Tout d'abord, nous passons en revue l'état de l'art pour les concepts fondamentaux de l'analyse de données qui recouvre principalement deux ensembles de techniques : l'analyse factorielle et de la classification automatique. Il s'agit de l'analyse en composantes principales (ACP) comme un exemple d'une technique de l'analyse factorielle et les cartes auto-organisatrices de Kohonen (SOM) ainsi que la classification ascendante hiérarchique (CAH), qui sont les plus élaborées des méthodes de classification automatiques. Un exposé assez exhaustif des bases théoriques de ces trois méthodes de la sélection des caractéristiques à base d'apprentissage automatique dans un but de réduction de dimensionnalité est présenté.

Le prochain chapitre fera l'objet d'implémentations théorique de techniques de classification et de régression basées sur l'apprentissage statistique supervisé et appliqué sur des données multi-sensorielles. Passons en revue à nouveau, notre objectif est d'appliquer ces technologies comme une solution pour la conception de capteurs logiciels et la surveillance de la qualité de l'eau grâce à la reconnaissance de formes.

CHAPITRE III

TECHNIQUES DE CLASSIFICATION ET REGRESSION

Introduction

Résoudre des problèmes en construisant des machines qui peuvent apprendre des sorties et des entrées est une approche essentielle de la théorie de l'apprentissage statistique. Les problèmes typiques de la théorie de l'apprentissage statistique peuvent être résumés comme des situations où les données sont générées par des distributions de probabilité (phénomènes physiques), divisées en classes dans le cas de la classification des données, ou des situations où une régression de sortie souhaitée peut être prédite. Nous voulons profiter d'un échantillon limité de ces données pour construire des lois générales qui nous permettent de classer ou de prédire de nouveaux points tirés de la même distribution. Cette problématique d'apprentissage supervisé de données est considérée comme l'un des principaux problèmes d'extraction de connaissances à partir de données. Au fil des décennies, de nombreux sous-problèmes ont été identifiés, l'extraction et la sélection de caractéristiques pour la réduction de la dimensionnalité, la diversité des espaces de représentation, la popularité, la complexité et toutes ces variantes de problèmes d'apprentissage, résultant en de multiples solutions. Pour traiter les problèmes dans ce sens, diverses méthodes ont été développées. Ceux-ci incluent les réseaux de neurones artificiels (RNA), les machines à vecteurs de support (SVM) et les réseaux récurrents à mémoire court et long terme (LSTM).

Dans le cadre de nos travaux, rappelons à nouveau que la solution retenue est de surveiller et de contrôler la qualité de l'eau grâce à des techniques de reconnaissance de formes. Ainsi, dans ce chapitre, nous pourrions passer en revue les méthodes d'apprentissage statistique appliquées à la classification et à la régression. Après une brève introduction, nous rappellerons le concept de neurone formel, décrirons son architecture et rappellerons les propriétés générales des réseaux de neurones artificiels statiques

(perceptrons multicouches) à apprentissage supervisé et les réseaux de neurones récurrents. Les aspects théoriques et les fondements de l'apprentissage statistique sont ainsi décrits. La formulation générale des méthodes SVM appliquées à la classification (binaire) et à la régression est également décrite. Enfin, Un réseau récurrent à mémoire court et long terme (Long short-term memory (LSTM), en anglais) est introduit.

3.1. Réseaux de neurone artificiels

Aujourd'hui, plusieurs termes sont utilisés dans la littérature pour montrer le domaine des réseaux de neurones artificiels (RNA), comme le connexionnisme ou la simulation neuronale. Selon nous, chacun de ces noms doit être associé à une sémantique précise. Par conséquent, le réseau de neurones artificiels se réfère uniquement à la manipulation de modèles ; ce n'est ni un domaine d'étude ni une discipline scientifique. Le connexionnisme et la simulation neuronale sont deux domaines d'étude en soi, manipulant tous deux des modèles de RNA, mais avec des objectifs distincts. L'objet poursuivi par les ingénieurs et chercheurs connexionnistes est d'amplifier la puissance de calcul en utilisant des modèles à composants fortement connectés. De leur côté, les neuro-simulateurs utilisent des modèles de RNA afin de valider leurs hypothèses biologiques sur le fonctionnement du système nerveux central [106].

3.1.1. Définitions

Avant d'introduire le concept technique de réseaux de neurones artificiels, on va commencer par des définitions des mots "réseau", "neurone" et "artificiel" :

- **Vocabulaire 1 (Nom) :** Un réseau est un ensemble ordonné dont les éléments sont distribués en différents points, interconnectés pour assurer leur communication.
- **Vocabulaire 2 (Nom) :** Les neurones sont des cellules basées sur des tissus nerveux capables d'analyser, acquérir et de produire des informations.
- **Définition 1 :** Le réseau de neurones est un graphe conduit, composé d'un ensemble d'unités, exécutant des traitements de base, construites sous la forme de couches successives reliées capables de transformer les informations à travers des liens structurés.

Un réseau neuronal artificiel inspiré de concepts biologiques n'est qu'un modèle mathématique de ce graphe. Ainsi, ils reproduisent certaines caractéristiques de l'analyse neurobiologique (l'aptitude d'apprendre, d'enregistrer des informations et traiter des informations endommagées ou incomplètes). Depuis l'introduction du concept, plusieurs modèles neuronaux ont été proposés. Les modèles artificiels proposés dans une perspective

connexionniste s'appuient sur des modèles biologiques de structure et de comportement global. Ainsi, les principes d'interconnexion et de parallélisme sont toujours respectés, quels que soient les principes de structuration, les RNA ont fait leurs preuves.

- **Vocabulaire 3 (Adjectif) :** La manipulation résulte un produit artificiel.
- **Définition 2 :** Un réseau neuronal artificiel est un réseau fortement connecté de processeurs de base qui fonctionne en parallèle. Tout processeur de base calcule une sortie basée sur les informations reçues en entrée. Toute hiérarchie de réseaux est certainement un réseau distinct [107].

3.1.2. Historique

L'origine de l'inspiration pour les réseaux de neurones artificiels remonte à 1890, lorsque le célèbre psychologue américain W. James a proposé le concept de mémoire associative. Il a proposé ce qui allait devenir la loi de fonctionnement des réseaux de neurones d'apprentissage, plus tard la loi de Hebb. Quelques années plus tard, en 1949, J. Mc Culloch et W. Pitts donnent son nom au modèle du neurone biologique (neurone à comportement binaire). Ils ont d'abord démontré que de simples réseaux de neurones formels peuvent exécuter des fonctions logiques, arithmétiques et symboliques complexes. C'est alors que le physiologiste américain D. Hebb propose en 1949 les propriétés des neurones agissant sur les animaux par conditionnement. Ainsi, le conditionnement pavlovien, comme nourrir le chien à la même heure chaque jour, fait saliver l'animal à ce moment précis, même en l'absence de nourriture. Ce résultat expérimental s'explique en partie par sa proposition de modification des propriétés des connexions entre neurones.

La première réussite de la discipline remonte à 1957, quand F. Rosenblatt a développé le perceptron. Il construit le 1^{er} ordinateur neuronal sur la base de ce modèle et il a utilisé pour la reconnaissance de formes. À l'époque, les moyens dont il disposait étaient limités, et c'était une prouesse technique d'arriver à faire fonctionner la machine pour quelques minutes. En 1960, l'automaticien Widrow a développé le modèle Adaline (Adaptive Linear Element). La structure de ce modèle est similaire à un perceptron, mais avec des lois d'apprentissage différentes.

C'est l'origine de l'algorithme de rétro propagation de gradient largement utilisé dans les perceptrons multicouches aujourd'hui. M. Minsky et S. Papert ont publié un article en 1969 qui soulignait les limites théoriques des perceptrons [34]. Ces limitations sont liées à l'incapacité de gérer des problèmes non linéaires à l'aide de ce modèle.

Suivent quelques années d'ombres, de 1967 à 1982. Le renouvellement de la discipline reprend grâce au physicien J. J. Hopfield en 1982. Dans un article clair, bref et bien écrit, il a développé une théorie sur les capacités et les possibilités des RN. Notez l'introduction non conventionnelle de son article.

Alors que les auteurs ont jusqu'à présent insisté sur la proposition de lois de structure et d'apprentissage, lors de l'étude des propriétés émergentes, JJ Hopfield fixe d'abord le comportement que son modèle est censé atteindre, et à partir de là construit les lois de structure et d'apprentissage correspondant aux résultats attendus. Ce modèle est encore largement utilisé aujourd'hui pour des problèmes d'optimisation. On peut également citer la machine de Boltzmann de 1983, le premier modèle connu qui gère de manière satisfaisante les limitations rencontrées dans le cas du perceptron. Mais il est difficile à utiliser en pratique, le temps de convergence de l'algorithme est extrêmement long (le temps de calcul est assez long). Puis, en 1985, il y a eu une rétro propagation par gradient. C'est un algorithme d'apprentissage adapté aux perceptrons multicouches. Ses conclusions ont été faites par trois groupes de chercheurs indépendants. Sur la base de cette constatation, il est possible d'implémenter une fonction d'entrée/sortie non linéaire sur le réseau en décomposant cette fonction en une série d'étapes linéairement séparables. Enfin, en 1989, Moody et Darken ont proposé un réseau de fonctions de base radiales (RFR) utilisant certains résultats d'interpolation multi variée, le nom anglais Radial Basis Function network (RBF). Ce qui distingue ce type de réseau des autres types de réseaux de neurones est sa représentation locale [25].

3.1.3. Intérêts pour l'utilisation des RNA

Les réseaux de neurones formels, tels que nous les définirons dans les paragraphes suivants, ont des propriétés approximatives et peuvent être formulés comme suit :

Toute fonction délimitée suffisamment régulière peut être approximée avec une précision arbitraire dans le champ fini de son espace variable. Un réseau de neurones se compose d'une couche d'un nombre fini de neurones cachés, qui ont tous la même fonction d'activation et la même sortie linéaire de neurones.

De plus, les réseaux de neurones nécessitent moins de paramètres ajustables (poids de connexion) que d'autres outils mathématiques couramment utilisés. En pratique, les réseaux de neurones ne sont pas utilisés pour effectuer des approximations de fonctions connues. La plupart du temps, le problème qui se pose est de trouver la relation entre un

ensemble de sorties dans un processus donné et un ensemble d'entrées correspondantes à travers les mesures effectuées. Nous admettons que cette relation existe malgré : le nombre limité des mesures, ils doivent être pollués par le bruit et toutes les variables qui déterminent le résultat d'un processus ne doivent pas être mesurées.

En d'autres termes, l'ingénieur recherche un modèle du procédé sur lequel il travaille à partir des mesures dont il dispose : disons qu'il effectue une modélisation "boîte noire". Dans la « grammaire » des réseaux de neurones, les données sur lesquelles nous cherchons à construire un modèle sont appelées exemples. Par conséquent, la raison pour laquelle les réseaux de neurones sont considérés comme un bon choix est qu'une approximation peut être trouvée à partir des mesures disponibles du modèle RNA.

En général, les réseaux de neurones utilisent mieux les mesures disponibles que les méthodes d'approximation non linéaires traditionnelles. Ce gain peut être considérable lorsque le procédé à modéliser dépend de plusieurs variables, comme dans le cas de plusieurs types de non-linéarités et de procédés de mise en forme où plusieurs paramètres matériels et techniques interviennent [108].

3.1.4. Concept neurobiologique

Les éléments essentiels du système nerveux central sont les neurones. Le cerveau est composé de proximité un billion de neurones, chacun avec 1000 à 10000 synapses ou bien connexions.

Les neurones sont des cellules composées d'un noyau et d'un corps cellulaire (Figure 3.1.). Le corps cellulaire ramifie pour composer ce qu'on appelle des dendrites. Celles-ci sont si nombreuses parfois qu'on parle de poils dendritiques ou de structures dendritiques. L'information est transmise de l'extérieur vers le corps cellulaire (corps neuronal) par les dendrites. Ensuite le corps cellulaire traite l'information. Une fois le potentiel d'action surpasse un certain seuil, le corps cellulaire répond au stimulus (Fig. 3.2, (a).). Le signal transmis par le neurone voyage alors le long de l'axone (unique) vers d'autres neurones. La transmission entre deux neurones n'est pas directe. En effet, il existe un gap cellulaire de plusieurs dizaines d'angströms entre les axones des neurones afférents et les dendrites des neurones efférents. La connexion entre deux neurones s'appelle une synapse (Fig. 3.2, (b).) [25].




Fig. 3.1. Structure d'un neurone biologique.




Fig. 3.2, (a). Potentiel d'action. (b) Opération au niveau synaptique (a) L'arrivée d'un potentiel d'action. (b) Libération de neurotransmetteurs dans l'espace synaptique.

3.1.5. Les modèles mathématiques

De nombreuses applications telles que la reconnaissance de formes, le traitement du signal, l'apprentissage d'exemples, la mémoire, la généralisation, etc. sont facilement mises en œuvre par les réseaux de neurones biologiques. Cependant, malgré tous les efforts en algorithmes et en intelligence artificielle, ces applications sont encore à la limite des possibilités actuelles. Les RNA sont basés sur le principe que le comportement intelligent découle du comportement des éléments de base du cerveau et de la structure. Les RNA sont des modèles, ils peuvent donc être décrits par leurs composants, leurs variables descriptives et les interactions des composants.

3.1.6. Structure de neurone artificiel

La figure 3.3 montre la structure du neurone artificiel. Chaque neurone artificiel est un processeur de base. Il reçoit un nombre variable d'entrées des neurones en amont. Chacune de ces entrées est associée à une abréviation de poids w qui indique le poids de la force de connexion. Chaque processeur de base à une sortie, qui se ramifie ensuite pour fournir un nombre variable de neurones en aval. Chaque connexion est associée à un poids [106].

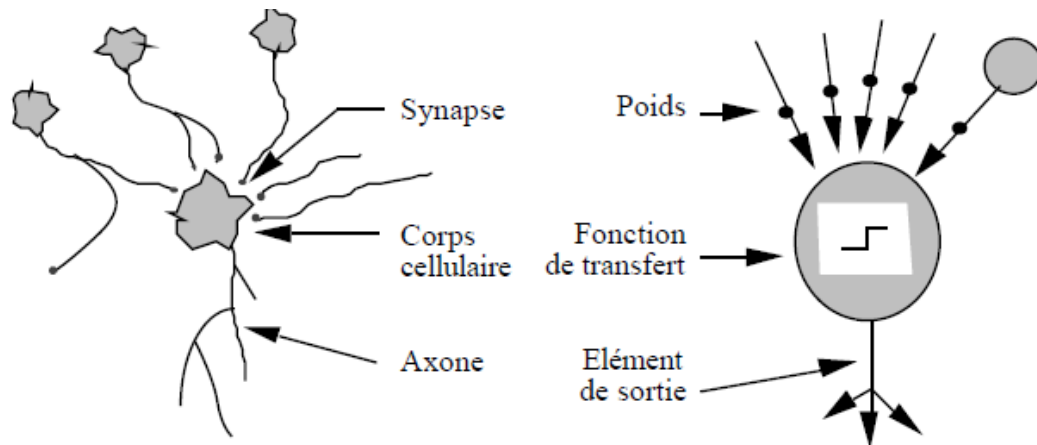


Fig. 3.3. Faites correspondre les neurones biologiques/neurones artificiels.

3.1.7. Comportement

Au cours de fonctionnement d'un RN, les neurones formels produisent des sorties variables basées sur les propriétés d'entrée du milieu externe ou sur les propriétés d'entrée des neurones voisins en fonction de leur position dans le réseau. La valeur différentielle est la variable de sortie est qui permet de spécifier l'état actif ou inactif du neurone.

Après avoir reçu les attributs d'entrée, ces derniers dépassent par une fonction de pondération avec des poids de connexion. Toutes les valeurs pondérées sont ensuite transmises à la fonction de combinaison, et la somme pondérée est calculée aussi.

Enfin, la somme sera transmise à la fonction d'activation qui est généralement identifiée par la fonction de transfert. Cette dernière permet d'engendrer une valeur de sortie basée sur un seuil introduit en paramètre. Il existe plusieurs formes de fonctions de transfert dans la littérature.

En résumer, la valeur de sortie d'un neurone est calculé à l'aide de l'équation 3.1. L'aspect de cette équation reflète la non-linéarité du traitement qui se base sur le réseau neuronal. La valeur de sortie représente l'état du neurone, qui sera déclenché directement vers l'environnement externe ou vers les neurones en aval [107].

$$S = f\left(\sum_{i=1}^D \|x_i \cdot w_i\|\right) \quad (3.1)$$

3.1.8. Fonctions d'activation

Les fonctions de transfert jouent un rôle important dans les réseaux de neurones, et le tableau 3.1 montre les différents types de fonctions de transfert et la relation entre les entrées et les sorties des neurones :

Tableau. 3.1. Fonctions de transfert $a = f(n)$.

Nom de la fonction	Relation d'entrée/sortie	Icone
Seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
Seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
Linéaire	$a = n$	
Linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
Linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
Linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
Sigmoïde	$a = \frac{1}{1 + \exp^{-n}}$	
Tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Compétitive	$a = 1$ si n maximum $a = 0$ autrement	

Parmi ces fonctions, il en existe trois les plus utilisées dans le domaine de l'ingénierie. Ces fonctions sont : "seuil" (a) ("limite dure"), "linéaire" (b) et "sigmoïde" (c) comme le montre la figure 3.4 :




Fig. 3.4. Les fonctions les plus utilisées adaptées en ingénierie.

Comme son nom l'indique, une fonction de seuil applique un seuil à son entrée. Plus précisément, la fonction renvoie la valeur 0 (faux) pour les entrées négatives qui ne dépassent pas le seuil, et 1 (vrai) pour les entrées positives ou vides. Il est évident que ce genre de fonction permet de prendre des décisions binaires.

Une fonction linéaire est simple, elle affecte directement son entrée à sa sortie selon la relation $n = f(n) = n$. Il est clair que la sortie d'un neurone correspond à son niveau d'activation, qui passe par zéro (l'ordonnée de l'origine) lorsque $W.p = b$

La fonction de transfert sigmoïde est σ . Les deux sont définis par la relation mathématique :

$$a = \frac{1}{1 + e^{-n}} \quad (3.2)$$

Cela ressemble à une fonction de seuil ou à une fonction linéaire, selon que nous sommes loin ou près de b , respectivement. La fonction de seuil est très non linéaire car il y a une discontinuité lorsque $W.p = b$. Les fonctions linéaires, en revanche, sont complètement linéaires. Il n'inclut aucun changement de pente. Sigmoïde est un compromis intéressant entre les deux premiers. Enfin, notez que la fonction tangente hyperbolique est une version symétrique de la sigmoïde [109].

3.1.9. Architectures d'un réseau de neurones

Généralement, les réseaux de neurones se composent de trois types de couches :

- **La couche d'entrée** : C'est la première couche. Il recevra les données sources que nous voulons utiliser pour l'analyse. Sa taille est directement déterminée par le nombre de variables d'entrée.
- **La couche cachée** : c'est la couche suivante après la couche d'entrée, nous pouvons avoir une ou plusieurs couches cachées dans le réseau. Nous notons que si la fonction de transfert est linéaire, nous traitons toutes les couches cachées comme une seule couche. Cependant, la fonction d'activation est généralement non linéaire à cette couche, mais n'obéit pas aux règles. Le choix de sa taille n'est pas implicite et doit être ajusté. En général, on peut commencer avec des couches d'entrée et de sortie de taille moyenne, mais ce n'est pas toujours le meilleur choix. Il est généralement préférable d'obtenir de bons résultats et d'en essayer autant que possible.

- **La couche de sortie** : C'est la troisième couche. Il donne le résultat obtenu après que les données entrées dans la première couche ont été compilées par le réseau. Sa taille dépend directement par le nombre de variables que nous voulons en sortie [109].




Fig. 3.5. L'architecture d'un réseau de neurones.

3.1.10. Apprentissage

L'apprentissage est une étape très importante dans le développement des réseaux de neurones, où le comportement du réseau est modifié de manière itérative jusqu'à l'obtention du comportement souhaité, ce qui est obtenu en ajustant les poids (connexions ou synapses) des neurones à des informations sources bien définies. L'apprentissage comprend également l'extraction de la cohérence entre les données utilisées pour la formation du réseau, mais l'objectif fondamental de l'apprentissage est de résoudre des problèmes par la prédiction, la classification, etc.

Pour les réseaux de neurones artificiels, l'apprentissage peut également être considéré comme le processus de mise à jour des poids (connexions) dans le réseau pour ajuster la réponse du réseau à l'expérience et aux exemples.

Il existe de nombreux types de règles d'apprentissage, qui peuvent être divisées en deux catégories, à savoir l'apprentissage supervisé et l'apprentissage non supervisé.

❖ **Apprentissage supervisé** : Dans ce type d'apprentissage, on essaie d'imposer une fonction donnée au réseau en forçant la sortie du réseau à prendre une valeur donnée (choisie par l'opérateur) et en modifiant les poids synaptiques.

Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés en fonction du couple entrée-sortie présenté.

L'adaptation des paramètres du réseau est effectuée par un algorithme d'optimisation, et l'activation des poids synaptiques est généralement aléatoire. Des exemples d'utilisation de différentes règles d'apprentissage, architectures et algorithmes associés à ce type de supervision sont présentés dans le tableau 3.2.

Tableau. 3.2. Exemple de différents types d'apprentissages en mode supervisé.

Paradigme	Architecture	Règle d'apprentissage	Algorithme	Taches
Supervisé	Perceptron simple ou multicouches	Correction d'erreur	Perceptron, Rétro-propagation, Adaline, Madaline	Classification, Approximation de fonctions, Prédiction, Contrôle
	Récurrente	Boltzmann	Apprentissage de Boltzmann	Classification
	Multicouches non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données, Classification
	à compétition	Par compétition	LVQ	Catégorisation au sein d'une classe, Compression de données
	ART		ARTMap	Classification, Catégorisation au sein d'une classe

❖ **Apprentissage non supervisé** : Contrairement à l'apprentissage supervisé, cet apprentissage non supervisé est aussi appelé « apprentissage compétitif » où seules les valeurs d'entrée sont disponibles. Dans ce cas, les exemples présentés à l'entrée amènent le réseau à générer de manière adaptative des valeurs de sortie proches en réponse à des valeurs d'entrée similaires.

Des exemples d'utilisation de différentes règles d'apprentissage, architectures et algorithmes associés à ce type de supervision sont présentés dans le tableau 3.3 [110].

Tableau. 3.3. Exemple de différents types d'apprentissages en mode non supervisé.

Paradigme	Architecture	Règle d'apprentissage	Algorithme	Taches
Non supervisé	Multicouches non bouclés	Correction d'erreur	Projection de Sammon	Analyse de données
	Non bouclé ou à compétition	Hebb	Analyse en composantes	Analyse de données,
	à compétition	Par compétition	VQ	Catégorisation, Compression de données
	Carte de Kohonen		SOM	Catégorisation, Analyse de données
	ART		ART-1, ART-2	Catégorisation

3.1.11. Modèles des RNA

Pour engendrer un réseau de neurones, nous devons mettre des connexions entre les neurones. Nous avons quatre principaux types de connexions : les connexions directes, les connexions récurrentes, les connexions latérales et les connexions différées. Tous les réseaux de neurones utilisent des connexions directes pour transmettre les informations de l'entrée à la sortie. Des connexions récurrentes permettent de transmettre des informations depuis les sorties des neurones de la couche supérieure vers les entrées des neurones précédents.

Les réseaux de neurones qui doivent sélectionner le neurone gagnant utilisent des connexions latérales pour établir la relation entre les neurones de sortie et la maintenir. Enfin, le problème de synchronisation est résolu par un modèle de réseau dynamique avec des connexions temporisées. Les connexions entre les neurones peuvent être complètes ou partiellement complètes. Quand les neurones de la couche inférieure sont reliés aux neurones de la couche supérieure, la connexion est complète, et quand les neurones des deux couches ne sont pas complètement reliés, la connexion est locale.

Une couche est définie comme un groupe de neurones situé au niveau d'un réseau de neurones. Par exemple, nous avons une couche de neurones de sortie et une couche entre l'entrée-sortie appelée la couche cachée. Les réseaux de neurones ont une ou plusieurs

couches de neurones, et leur taille dépend du nombre de couches et du nombre de neurones dans chaque couche [111].

❖ Perceptron

Multi-Layer Perceptron (MLP) en anglais, est le réseau de neurones utilisé souvent pour les fonctions d'approximation, de prédiction et de diagnostic. Son architecture est conçue pour que le flux de données voyage dans une seule direction (de l'entrée à la sortie) et à travers les couches médiatrices du réseau. Généralement, ce modèle utilise des règles d'apprentissage supervisé. L'algorithme le plus utilisé pour MLP est la rétro propagation des gradients, où les informations sont propagées dans des directions opposées pour s'adapter aux paramètres libres.

- **Perceptron simple** : c'est un cas spécifique de MLP. Comme le montre la figure 3.6, un perceptron simple est une architecture constituée d'une couche unique de neurones duquel la fonction d'activation est de type «pas unitaire». Tous ces neurones sont alimentés par D éléments de la couche d'entrée (D est la dimension du vecteur de poids W associé au neurone). L'entrée sera traitée par les neurones et présentée à la fonction d'activation. Cette fonction va déterminer l'état d'activation du neurone et présenter le résultat sur la sortie S .

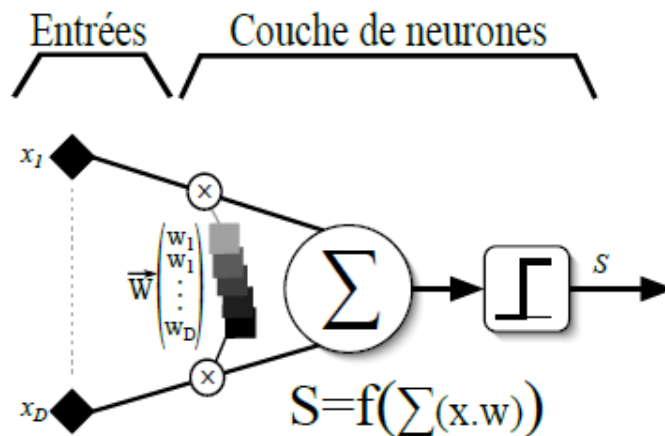


Fig. 3.6. Perceptron Simple.

Malgré la simplicité de l'algorithme utilisé et de cette architecture, les perceptrons simples sont très utiles pour les fonctions d'ordre linéaires. Cependant, des difficultés surgissent si les deux classes sont linéairement inséparables. Dans ce cas, des couches supplémentaires de neurones doivent être ajoutées. Par conséquent, le perceptron multicouche se présente comme une solution [107].

• **Perceptron multicouches (PMC)** : (Modèle utilisé dans cette étude) est un ensemble de plusieurs perceptrons simples connectés les uns aux autres en N couches (Figure 3.7). Selon cette implémentation, L'écoulement de données ne se déplace que de l'entrée vers sortie. Les neurones d'une couche sont fournis par les sorties des couches adjacentes. Il existe deux types de calques selon leur disposition :




Fig. 3.7. Schéma de principe d'un PMC.

La couche de sortie est fréquemment appelée couche de décision. Elle est à droite. Au niveau de cette couche, le résultat final du traitement est récupéré. Par conséquent, la quantité de neurones sur cette couche dépend du résultat souhaité. Cette couche peut être rendue par un simple perceptron. Entre autres choses, il est probablement présenté par d'autre modèle neuronal (ADALINE). Il a la même structure qu'un perceptron simple, sauf que les neurones utilisés ont des fonctions d'activation linéaires.

Couche cachée ou couche de prétraitement. Ces couches sont situées entre la couche d'entrée et la couche de sortie. Ce qu'ils font, c'est utiliser principalement des fonctions d'activation non linéaires dans les neurones pour préparer les données à présenter à la couche de sortie. Pour que cela fonctionne, les couches doivent être de type perceptron simple, et non pas de modèle ADALINE. Puisque, la combinaison de plusieurs fonctions linéaires donne une seule fonction linéaire. Le nombre de neurones dans chaque couche cachée et le nombre de couches cachées dépend du traitement exécuté et du comportement souhaité du réseau [107].

❖ Réseau RBF

Les réseaux RBF sont des réseaux hiérarchiques dérivés d'une technique d'interpolation appelée méthodes d'interpolation RBF. Le réseau est constitué d'une couche cachée dont la fonction d'activation est appelée fonction noyau ou fonction gaussienne, et d'une couche de

sortie avec une fonction d'activation linéaire. La particularité de la méthode RBF est sa réponse utile aux plages restreintes. La réponse de la fonction noyau est la plus grande au niveau du noyau et diminue généralement de manière monotone avec la distance existant entre le vecteur d'entrée et le centre de la fonction noyau. Pour approximer un comportement donné, les fonctions de base sont assemblées pour couvrir toutes les données d'entrée à travers leurs champs récepteurs. Ces fonctions sont ensuite pondérées et leurs valeurs additionnées pour produire la valeur de sortie. Les réseaux RBF sont capables de calculs puissants. Par rapport aux réseaux multicouches, l'apprentissage est plus rapide et plus simple, mais nécessite un grand nombre de neurones. De plus, ils sont beaucoup moins sensibles à la destruction du poids corporel. Leurs champs d'application sont très larges : traitement d'images, reconnaissance de formes, et surtout problèmes de classification [111].

❖ Réseau Hopfield

Un réseau Hopfield implémente une mémoire adressable par son contenu. C'est un réseau de neurones de McCulloch et Pitts (à deux états, -1 et 1 ou 0 et 1), Sa règle d'apprentissage est la règle de Hebb (1949), qui stipule qu'une synapse augmente son activité si et seulement si l'activité de ses deux neurones est courante (c'est-à-dire que lorsque deux neurones sont activés simultanément, le poids w_{ij} d'une connexion entre les neurones i et j est augmenté au même temps) [110].

❖ Les réseaux de Kohonen

Contrairement aux réseaux Hopfield, qui modélisent les neurones de la manière la plus simple, ces réseaux s'inspirent d'observations biologiques du fonctionnement du système nerveux sensoriel des mammifères. Une loi de Hebb modifiée (tenant compte de l'oubli) est utilisée pour l'apprentissage. Cette connexion est renforcée lorsque les neurones connectés sont actifs en même temps, et affaiblie dans le cas contraire. Par conséquent, la loi d'interaction latérale (observée biologiquement) est également simulée. Les neurones très proches (physiquement) interagissent positivement (le poids de la connexion augmente lorsque les synapses sont activées), négativement pour les neurones ultérieurs, et pas du tout pour les neurones distants. Les réseaux Kohonen ont des applications dans la classification, le traitement d'images, l'aide à la décision et l'optimisation [110].

❖ Réseau de neurone récurant

Contrairement aux MLP, les réseaux de neurones récurrents (RNN), comme le montre la figure 3.8, ont des cycles dans le graphe neuronal (Elman, 1990). La principale motivation derrière cette architecture est de pouvoir manipuler une séquence de vecteurs d'entrée, chaque vecteur représentant un événement temporel, et pas seulement des données isolées sans signification temporelle. En déroulant la modélisation compacte des RNN par rapport au temps (voir Figure 3.9), ce type de réseau peut ainsi être vu comme une série temporelle de réseaux MLP reliés entre eux par leurs couches cachées respectives. Cette liaison permet au RNN de coder les dépendances latentes entre les événements de la séquence vectorielle d'entrée.

Selon cette modélisation, le RNN prend une séquence d'événements en entrée $x = (x_1, x_2, \dots, x_T)$ et définit la séquence d'états cachés $h = (h_1, h_2, \dots, h_T)$ pour produire la séquence de vecteurs de sortie $y = (y_1, y_2, \dots, y_T)$ en itérant de $t = 1$ à T :

$$h_t = H(w_{xh}x_t + w_{hh}h_{t-1} + b_h) \quad (3.3)$$

$$y_t = w_{hy}h_t + b_y \quad (3.4)$$

Où T est le nombre total de vecteurs d'entrée, $w_{\alpha\beta}$ est la matrice de poids entre les couches α et β et b_β est le vecteur de biais de la couche β . La fonction H utilisée dans le cas des RNN est généralement la tangente hyperbolique [112].




Fig. 3.8. Une représentation compacte d'un RNN. Toutes les flèches représentent des connexions complètes. Les flèches en pointillé indiquent les connexions avec un décalage dans le temps ($t - 1$).




Fig. 3.9. Une représentation élargie d'un RNN.

❖ Deep Learning

Dans les algorithmes classiques d'apprentissage statistique et après la collecte des données, trouver des descripteurs pertinents est la première difficulté pour présenter les données et posséder des informations utiles pour la fonction désirée. Ainsi, plusieurs types de descripteurs pour chaque modèle considéré peuvent être investigués jusqu'à ce qu'une description satisfaisante des données soit trouvée. L'usage de descripteurs géométriques est un moyen courant d'obtenir des descripteurs.

Le risque est que le jeu de descripteurs soit redondant ou incomplet. Autre problématique qui concerne la collecte des données, dont la qualité peut varier. De plus, les échantillons de la base d'apprentissage doivent être représentatifs des données sur lesquelles le modèle est construit.

Les RNA correspondent à des associations dans un graphe d'objets élémentaires qui s'appelle neurones formels. La structure du graphe (les couches par exemple), la complexité (la présence de boucles de rétroaction par exemple), les fonctions d'activation des neurones (sigmoïde par exemple) sont des exemples standards de distinction des réseaux de neurones. Il est possible de distinguer l'entrée d'un neurone en tant que dendrites. Les connexions avec d'autres neurones sont considérées comme des synapses, les fonctions d'activation sont considérées comme des noyaux et les sorties sont activées en fonction des stimuli entrant et sortant des neurones, une analogie avec les réseaux neuronaux biologiques peut être établie comme axone.

L'apprentissage en profondeur (par opposition à l'apprentissage superficiel) est effectué sur un RN à nombreux couches cachées, son principe est un apprentissage couche par couche basé sur un apprentissage hiérarchique. Entre chaque couche, une transformation non linéaire se produit et chaque couche va recevoir une sortie de la couche antécédente en entrée. Dans l'apprentissage en profondeur, l'extraction des descripteurs est directement dirigée à partir des données [113]. En d'autres termes, l'apprentissage en profondeur repose donc sur un exemple d'apprentissage que l'on peut qualifier de "supervision des entrées" - où la sortie attendue du modèle est l'entrée elle-même. Dans cet exemple, l'apprentissage procède d'une fonction de coût (identiquement comme l'apprentissage supervisé) sans présenter de données de sortie (identiquement comme dans l'apprentissage non supervisé).

Les informations contenues dans les données peuvent être représentées de distinctes façons. Par exemple, on peut encodée une image sous la forme d'un vecteur de valeurs d'intensité pour chaque pixel, ou d'un ensemble de contours ayant une forme spécifique. Certaines présentations vous permettent de mieux apprendre une tâche particulière à partir d'exemples. L'un des avantages du l'apprentissage en profondeur est le remplacement de la détermination manuelle des descripteurs par des algorithmes qui extraient des descripteurs hiérarchiques [114].

Ça existe plusieurs manières de construire des réseaux de neurones profonds, dont le DBN (Deep Belief Network). Le moyen le plus populaire de former efficacement des réseaux de neurones profonds est l'apprentissage couche par couche via des machines Boltzmann restreintes utilisant des algorithmes gloutons (des algorithmes qui recherchent progressivement des minima locaux). Plus précisément, il s'agit d'une problématique d'apprentissage de chaque couche de manière non supervisée pour d'extraire les principaux descripteurs de la distribution des données d'entrée. Ainsi la première couche cachée correspond aux représentations de ces entrées. Cette représentation est utilisée comme entrée pour la couche suivante.

Les méthodes d'apprentissage profond peuvent être utilisées également comme initialisation des poids et des biais avant d'utiliser des algorithmes supervisés tels que la rétro propagation de gradient (cette méthode calcule le gradient de l'erreur pour chaque neurone du RN, de la dernière couche à la première couche. En apprenant une profondeur réseau, la rétro-propagation joue alors le rôle de fine-tuning). L'apprentissage de stratégies utilisant des réseaux aussi profonds est assez efficace. Il a été montré que l'utilisation d'un réseau profond (Deep Belief Network, ou type DBN) pour initialiser les poids d'un

perceptron multicouche donne de meilleurs résultats qu'une initialisation aléatoire. Il existe plusieurs modèles d'architecture de Deep Learning, en trouve : Auto-encodeur, CNN, LSTM, ... [115].

3.2. Les machines à vecteurs de support

Les machines à vecteurs de support ou les séparateurs à marge large (SVM) sont une classe d'algorithmes d'apprentissage statistique définis à l'origine pour la discrimination. Pour résoudre les problèmes de discrimination et de régression, SVM est considéré comme une généralisation des classificateurs linéaires [34].

L'origine des machines à vecteurs de support remonte à 1975, lorsque Vapnik et Chervonenkis ont proposé le principe du risque structurel et la dimension du VC (VC : Vapnik Chervonenkis) pour caractériser la capacité des machines à apprendre [116, 117]. A l'époque ce principe n'avait pas trouvé sa place car il n'existait pas encore de modèle de classification fiable pouvant être utilisé avec la théorie.

Il a attendu jusqu'en 1982 lorsque Vapnik a fourni le premier classificateur basé sur la minimisation des risques structurels (SRM), appelé SVM. Cependant, ce modèle est linéaire et nous ne savons pas encore comment introduire des frontières de décision non linéaires. En 1992, Boser et al [118] ont proposé d'introduire des noyaux non linéaires pour étendre SVM aux cas non linéaires. Par la suite, Cortes et Vapnik [119] ont introduit des paramètres de relaxation qui pourraient tolérer certaines erreurs d'apprentissage pour mettre fin à l'algorithme d'optimisation SVM qui fonctionnerait autrement indéfiniment.

3.2.1. Théorie de Vapnik-Chervonenkis :

Vapnik-Chervonenkis a déterminé les concepts de dimension VC et d'entropie VC, à partir desquels ils ont institué les conditions suffisantes et essentielles pour la convergence du risque empirique vers le risque réel [12, 120].

- La dimension VC h du modèle formé est la taille maximale des échantillons (un ensemble d'exemples) que le modèle peut éjecter ou séparer.
- L'entropie VC d'un modèle est l'attente de l'algorithme de la diversité (nombre de différentes séparations possibles) de toutes les fonctions que le modèle peut effectuer sur un échantillon d'une taille donnée.

Afin de garantir le risque, la seule façon est d'examiner la dimension VC h du modèle. Par conséquent, Vapnik a proposé de mettre un nouveau principe, qu'il appelle le principe

de minimisation des risques de structure MRS. Le principe repose sur la minimisation conjointe de 2 causes d'erreur : l'intervalle de confiance $\Gamma(h)$ (qui est une fonction croissante de la dimension VC) et le risque empirique [120].

Considérant une famille imbriquée de classes fonctionnelles $\phi_1 \dots \phi_k$, la minimisation de MRS consiste à désigner la classe ϕ_i telle que la borne supérieure sur l'erreur de généralisation peut être minimisée. Afin de solutionner cette problématique, a priori nous sélectionnons un ensemble de fonctions ϕ paramétrées par α . Choisir un ϕ approprié est une étape décisif, car un ensemble contraint peut ne pas séparer les données initiales, et inversement, un ensemble a trop de liberté peut conduire à un échec de généralisation (Figure 3.10).




Fig. 3.10. L'importance du choix de l'ensemble ϕ dans lequel est sélectionnée la fonction de décision.

• **Théorème :** Soit h la dimension du VC de la classe de fonction ϕ et $R_{emp}[f]$ le risque empirique déterminé [121]. En fait, pour tout l , on a déduit les inégalités suivantes, pour $l > h$, la probabilité est au moins égale à $1-n$, et pour tout $n > 0$, l'inégalité limitant le risque est donnée par (eq. 3.7) [121, 122].

$$R[f] = \int L(f(x, \alpha), y) dP(x, y) \quad (3.5)$$

$$R_{emp}[\alpha] = \frac{1}{l} \sum_{i=1}^l L(f(x_i, \alpha), y_i) \quad (3.6)$$

$$R[\alpha] \leq R_{emp}[\alpha] + \Gamma[h]$$

$$\text{avec : } \Gamma[h] = \sqrt{\frac{h(\log \frac{2l}{h} + 1) - \log(\frac{\eta}{4})}{l}} \quad (3.7)$$

l : c'est la taille de l'ensemble d'exemples.

L'objectif est de minimiser l'erreur de généralisation $R[f]$ en obtenant un faible risque empirique $R_{\text{emp}}[\alpha]$, tout en gardant la classe de fonctions la plus petite possible. L'inégalité (Équation 3.7) révèle deux cas extrêmes :

- Très petite classe de fonctions (par. Ex. ϕ_1) qui réduit le terme de complexité (racine carrée) rapidement, néanmoins le risque empirique reste élevé ;
- Très grande classe de fonctions (par ex. ϕ_k) avec peu de risque empirique mais une explosion de complication terminologique.

La meilleure classe de fonctions se situe couramment entre la plus petite et la plus grande, car on recherche une fonction qui éclaircir le mieux les données tout en maintenant un risque empirique faible (figure 3.11) [123, 124].

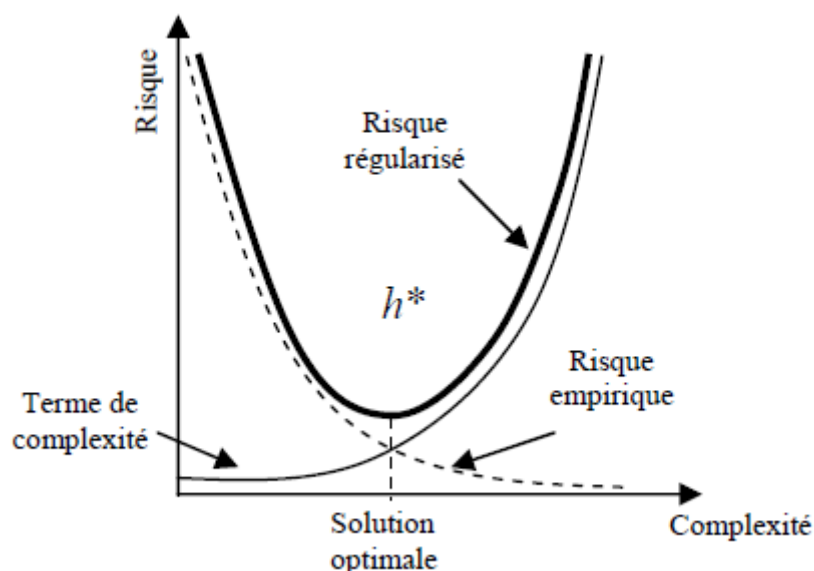


Fig. 3.11. Une illustration de l'inégalité structurelle des risques. La courbe croissante, appelée la confiance, correspond à une borne supérieure sur le terme de complexité [123].

Où h définit la "richesse" d'un ensemble de fonctions ϕ (elle est liée au nbre. max de points pouvant être convenablement séparés par des fonctions de ϕ , dite dimension de Vapnik-Chervonenkis) [117].

Par conséquent, nous pouvons voir que si la taille de l'échantillon l réduit et que la dimension VC h augmente (ϕ rich), la limite de risque augmente. On peut trouver des classificateurs avec des dimensions VC infinies, mais ils fonctionnent très bien. Cependant, il est souhaitable d'utiliser une fonction f générée à partir d'un ensemble ϕ de dimension VC la plus petite possible. Afin de deviner la valeur parfaite de h^* qui donnera le moins de

risque (voir Figure 3.11), il est donc nécessaire de minimiser à la fois le risque empirique et l'intervalle de confiance.

- **Définition de la dimension VC :** Fixons la dimension VC d'un ensemble de fonctions ϕ , notée h , en supposant que la famille f correspond à la ligne $y = ax + y_0 \in \mathbb{R}^2$, et la dimension VC de ϕ (figure 3.12) est 3, puisque, on trouve une configuration de 4 points (ou plus) rend cette discrimination possible [123].




Fig. 3.12. Les flèches indiquent le côté de la ligne où les points seront classés positivement [123].

3.2.2. Risque structurel

Le MRS divise les classes de fonctions en plusieurs structures imbriquées de plus en plus complexes, d'où le nom de risque structurel (figure 3.13). Le but de l'apprentissage est de trouver parmi ces structures celle qui réalise le meilleur compromis entre risque empirique et capacité de la machine. Ainsi, l'apprentissage commence de la plus petite structure vers la plus grande, mais s'arrête lorsque la somme des termes empiriques de risque et de confiance est la plus petite (Figure 3.11) [125].




Fig. 3.13. Structures imbriquées d'une classe de fonctions.

3.2.3. Principe des SVMs

SVM (les machines à vecteurs de support) sont conçues pour mettre en œuvre les principes de risque structurel. En raison de leur base théorique solide, ces classificateurs doivent connaître un grand succès dans différents domaines du traitement des données. De plus, ils abordent deux problèmes principaux de la théorie de l'apprentissage statistique :

- Contrôle de la capacité du classificateur.
- Sur ajustement des données.

De plus, SVM offre notamment deux autres avantages. D'une part, contrairement aux machines d'apprentissage classiques qui doivent définir un grand nombre de paramètres, les SVM ont des formulations élégantes qui laissent très peu de place aux paramètres utilisateurs. D'autre part, étant donné que l'erreur ne dépend pas de la dimensionnalité de l'espace d'entrée, les SVM sont très adaptés au traitement de données de très grande dimension telles que du texte et des images. L'apprentissage d'une SVM consiste à trouver un hyperplan permettant la meilleure séparation entre les deux classes de données. Minimisez l'erreur tout en maximisant la marge de séparation et en contrôlant la dimension VC du classificateur. [125]

❖ SVMs linéaires :

• Données linéairement séparables :

Considérons un ensemble de données d'apprentissage : $\{x_i, y_i\}; i=1, \dots, l$ avec : $x_i \in R^d$ et $y_i \in \{-1, +1\}$. Supposons que nous ayons un hyperplan séparant les données positives des données négatives. x_i appartenant à l'hyperplan vérifie la relation : $x_i \cdot w + b = 0$ Où w est la normale de l'hyperplan, et $|b| = \|w\|$ est la distance verticale entre l'hyperplan et l'origine (Figure 3.14).

L'algorithme de vecteur de support recherche simplement l'hyperplan séparateur qui permet la plus grande séparation entre les exemples des deux classes. Ceci est représenté par l'inégalité suivante [120, 126] :

$$x_i \cdot w + b \geq +1, y_i = +1 \quad (3.8)$$

$$x_i \cdot w + b \leq -1, y_i = -1 \quad (3.9)$$

Et l'on écrira aussi [127] :

$$y_i(x_i \cdot w + b) - 1 \geq 0 \tag{3.10}$$




Fig. 3.14. Hyperplan de séparation linéaire pour les données séparables linéairement. (Les vecteurs de support sont encerclés).

Les points vérifiant l'équation 3.8 appartiennent à l'hyperplan $H_1 : x_i \cdot w = +1$ dont la normale w est la distance à l'origine $|1 - b / \|w\|$. De même, les points satisfaisant l'équation 3.9 appartiennent à l'hyperplan $H_2 : x_i \cdot w + b = -1$ sa normale est w et sa distance à l'origine est $|-1 - b / \|w\|$. Notez que H_1 et H_2 sont parallèles et qu'il n'y a pas de données d'entraînement entre eux. Donc, la distance entre ces hyperplans et l'hyperplan séparateur est : $d^+ = d^- = 1 / \|w\|$ dont la marge est égale à $2 / \|w\|$.

Par conséquent, la maximisation de la marge se fait en minimisant $\|w\|^2$, qui est un problème d'optimisation que les lagrangiens reformulent généralement pour deux raisons de simplification. La première est que les contraintes de 3.10 seront remplacées par des contraintes de multiplicateur lagrangien plus traitables. De plus, dans cette reformulation, seules les données d'apprentissage sont présentées sous la forme d'un produit scalaire. Cette propriété clé nous permet de généraliser ce problème au cas non linéaire. La fonction lagrangienne d'origine correspond à la différence entre la fonction objectif ($\frac{1}{2} \|w\|^2$) et la contrainte en 3.10 fois le multiplicateur α_i .

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^l \alpha_i \tag{3.11}$$

Le but est la minimisation de la fonction lagrangienne par rapport à w et b sous la contrainte que les dérivées premières de tous les multiplicateurs α_i s'annulent et $\forall i, \alpha_i \geq 0$.

Ce problème est convexe car la fonction objective elle-même est convexe, et nous préférons étudier sa forme duale. L'optimisation du SVM revient alors à maximiser le lagrangien dual (L_D) par rapport à α_i , sous la contrainte que ses dérivées premières par rapport à w et b s'annulent.

En forçant les gradients de L_p par rapport à w et b à s'annuler, on obtient :

$$W = \sum_i \alpha_i y_i x_i \quad (3.12)$$

$$\sum_i \alpha_i y_i = 0 \quad (3.13)$$

On obtient le dual lagrangien L_D :

$$L_D = \sum_i \alpha_i \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i x_j \quad (3.14)$$

Après optimisation, les points avec α_i strictement supérieur à 0, appelés vecteurs supports, appartient à l'un des hyperplans H1 ou H2. Ces points sont les plus proches de la frontière de décision et forment le plan divisé. Les autres points ne participent pas au calcul de la fonction de décision. De plus, la condition de Karush-Kuhn-Tucker (KKT) résume les contraintes que le processus d'optimisation doit vérifier [34].

- **Le principe de Karush-Kuhn-Tucker (KKT)**

Les conditions KKT pour le problème d'optimisation SVM sont les suivantes :

$$\frac{\partial}{\partial b} L_p = w_v - \sum_i \alpha_i y_i x_{iv} = 0, v = 1 \dots d \quad (3.15)$$

$$\frac{\partial}{\partial b} L_p = -\sum_i \alpha_i y_i = 0 \quad (3.16)$$

$$y_i(x_i \cdot w + b) - 1 \geq 0, i = 1 \dots l \quad (3.17)$$

$$\alpha_i \geq 0, \forall i \quad (3.18)$$

$$\alpha_i(y_i(x_i \cdot w + b) - 1) = 0, \forall i \quad (3.19)$$

d : Dimension des données.

Ces conditions sont nécessaires et suffisantes pour que w et b et α_i ainsi obtenus soient la solution du problème. En résumé, l'optimisation d'un SVM revient à trouver une solution à la condition KKT. Enfin, la fonction de décision est donnée par :

$$g(x) = \text{sign}\left(\sum_{i=1}^{V_s} \alpha_i y_i x_i^T + b\right) \quad (3.20)$$

V_s : Nombre de vecteurs de support.

Avec : $(\sum_{i=1}^{V_s} \alpha_i y_i x_i^T = w)$ et le seuil b peut être calculé à l'aide de l'équation 3.19, qui fonctionne pour les exemples où α n'est pas nul.

- **Les données non linéairement séparables**

Lorsque les données ne sont pas linéairement séparables (Fig.3.16), Cortes and Vapnik [124] proposent de relaxer les contraintes 3.8 et 3.9 en introduisant une variable $\xi_i \geq 0$, par exemple [128] :

$$x_i \cdot w + b_i \geq +1 - \xi_i, y_i = +1 \quad (3.21)$$

$$x_i \cdot w + b_i \geq -1 - \xi_i, y_i = -1 \quad (3.22)$$

$$\xi_i \geq 0, \forall i \quad (3.23)$$

Pour qu'une erreur se produise, ξ_i doit être supérieur à 1. La somme $\sum_i \xi_i$ constitue une borne supérieure sur le nombre d'erreurs de classification dans la bibliothèque d'apprentissage, contrôlant ainsi le risque empirique. Cependant, lorsque les classes à séparer se chevauchent fortement, par exemple à cause du bruit, il peut être assez grand si plusieurs ξ_i atteignent des valeurs très grandes. Dans ce cas, rien ne garantit que l'hyperplan calculé soit la solution optimale. Pour contrôler le coût de l'erreur, le terme de la fonction objectif $(\frac{1}{2} \|w\|^2)$ est remplacé par $\frac{1}{2} \|w\|^2 + c(\sum_i \xi_i)$. La seule différence avec l'hyperplan optimal est que dans ce cas les ξ_i ont une borne supérieure fixée par un paramètre C appelé paramètre de régularisation. Ce dernier contrôle le compromis entre l'erreur et la largeur de la marge sur les données d'apprentissage. Plus le C est grand, plus la pénalité d'erreur est grande.

Remarquons encore que pour l'exemple où les multiplicateurs de Lagrange sont dans l'intervalle $0 < \alpha_i < C$, ξ_i vaut zéro.




Fig. 3.15. Hyperplan de séparation linéaire pour les données non linéairement séparables.

❖ SVMs non linéaires

Naturellement, dans la reconnaissance de formes, les données doivent être séparées par une fonction de décision non linéaire. Pour généraliser SVM aux cas non linéaires, le noyau de Mercer est introduit, permettant de trouver une hyper-courbe qui marquera la frontière de décision entre les exemples positifs et négatifs. La figure 3.16 illustre la transformation de l'espace d'entrée en espace d'augmentation.




Fig. 3.16. Illustration de l'effet de changement d'espace (mapping) par une fonction noyau.

Les auteurs montrent que le problème d'optimisation reste généralement inchangé car il n'y a qu'un produit scalaire $x_i \cdot x_j$ est remplacé par le produit des projections dans l'espace $H : \phi(x_i) \cdot \phi(x_j)$. Les dimensions de cet espace peuvent être infinies, ce qui signifie que la connaissance explicite de ϕ n'est pas triviale. Pour contourner ce problème, le noyau (ou Kernel) de Mercer fait que $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ est utilisé pour calculer le produit entre

les projections de l'espace de données. La fonction lagrangienne duale de la fonction objective à maximiser devient [122] :

$$\text{Maximiser } \sum_{i=1}^l \alpha_i - \sum_{i=1}^{V_S} \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.24)$$

Sous les contraintes 3.8 et 3.9 Ainsi, nous obtenons un SVM opérant dans un espace de dimension infinie où toutes les considérations de la section précédente tiennent, puisque nous maintenons toujours une séparation linéaire, mais dans un espace différent. La fonction de décision devient [129, 130] :

$$g(x) = \sum_{i=1}^{V_S} \alpha_i y_i K(x_i, x) + b \quad (3.25)$$

❖ Algorithmes d'optimisation du SVM

En raison de sa taille considérable, le problème de programmation quadratique de SVM ne peut pas être résolu facilement avec des techniques standard. La matrice de gramme contient le nombre d'éléments égal au carré du nombre total de données. Au fil des ans, deux algorithmes ont été proposés pour ce fait. Ce sont des algorithmes de section ou de segmentation et des algorithmes de décomposition. Plus récemment, Platt a proposé un algorithme plus rapide appelé Min-Sum-Order Optimization (ou Sequential Min-Optimization SMO).

• Optimisation minimale et séquentielle SMO

SMO est un algorithme simple et rapide pour résoudre le problème PQ des SVM sans stocker de grandes matrices en mémoire. Comme d'autres algorithmes, il décompose le problème d'optimisation en plusieurs sous-problèmes, mais à chaque étape il optimise le plus petit problème possible. En effet, chaque étape optimise les valeurs des deux multiplicateurs lagrangiens. Cela dit, le principal avantage de SMO est que l'optimisation des deux multiplicateurs peut être effectuée de manière analytique.

De plus, SMO ne nécessite pas beaucoup d'espace de stockage. L'algorithme comprend principalement trois éléments :

- Une méthode analytique pour résoudre les problèmes de PQ.
- Choisit heuristiquement le multiplicateur à optimiser.
- Une méthode de calcul d'un seuil b [125].

3.3. Les réseaux récurrents à mémoire court et long terme

Les réseaux récurrents à mémoire court et long terme (Long short-term memory souvent abrégés en LSTM), sont un modèle particulier de RNN. Ils ont été présentés par Hochreiter Schmidhuber (1997). Le réseau de neurones récurrent montré dans la section précédente est théoriquement capable d'apprendre les règles de mise à jour de séquence arbitraires. En pratique, cependant, ces schémas sont souvent rapidement oubliés. C'est ce qu'on appelle le problème du gradient de fuite, de ce fait ils ont créé le LSTM. Les cellules LSTM sont une adaptation des couches récurrentes qui permettent aux anciens signaux des couches profondes de se propager à la cellule actuelle (Figure 3.17) [131, 132]. Le schéma ci-dessous montre une chaîne de 3 cellules LSTM :




Fig. 3.17. Une chaîne de cellules LSTM.

3.3.1. Présentation des LSTMs

Le concept de LSTM, Long Short Term Memory, vient de l'idée suivante : Dans RNN, les informations sont stockées dans deux formats. Les activations des unités représentent l'histoire récente du réseau et donc la mémoire à court terme du réseau, tandis que les poids de connexion entre neurones représentent l'expérience accumulée par le RNN au cours du processus d'apprentissage et donc la mémoire à long terme. Sur la base de cette observation, Hochreiter et Schmidhuber ont introduit les cellules de mémoire, une forme de mémoire intermédiaire qui permet de stocker des informations importantes pendant des périodes plus longues que les RNN existants. D'un point de vue technique, la motivation des LSTM est de fournir un modèle qui ne subit pas de problèmes de débordement ou de décroissance des erreurs lors de l'apprentissage. En fait, dans les RNN traditionnels comme Elman, l'apprentissage finit par émettre un faux signal à un moment donné, qui explose

(provoquant une augmentation des poids), Ou disparaître (en particulier lorsque le réseau doit apprendre ce qui prend beaucoup de temps avec un long retard ou ne marche pas). Mais sans erreur, il n'est plus possible pour un RNN d'apprendre. L'étude liée aux LSTM est un domaine très vif depuis 1997, avec de nombreuses variantes suggérées. Nous présenterons la version LSTM fournie par Gers et al dans la section suivante. C'est le premier produit à percer le modèle original en termes de performances [133].

3.3.2. Architecture d'une unité LSTM

De nombreuses fois, le concept de « cellule LSTM » (LSTM cell) se retrouve dans la littérature pour définir une cellule LSTM dans son ensemble. Afin d'éviter toute confusion, nous exploitons le terme cellule LSTM lors de la spécification des composants : bloc et cellule. Par conséquent, nous décrivons ci-après la structure globale de RNN-LSTM avant de clarifier respectivement les composants de bloc et de cellule.

❖ Comment les cellules LSTM s'intègrent dans RNN-LSTM

Dans un RNN comme Elman, le réseau est constitué de trois couches : couche d'entrée, couche cachée et couche de sortie. La couche cachée est constituée de neurones artificiels du même type que les couches d'entrée et de sortie. Dans LSTM, la structure réseau reste la même, c'est-à-dire 3 couches. La principale différence est la couche cachée. Les cellules utilisées sont alors des cellules LSTM composées de blocs et de cellules. Par conséquent, la couche cachée encaisse des informations de la couche d'entrée à l'instant t et reçoit également des informations de la couche cachée à l'instant $t-1$. Le motif actif de la couche cachée est constitué de toutes les sorties des différentes unités de chaque unité LSTM. La figure 3.18 montre un exemple de RNN-LSTM.




Fig. 3.18. Un réseau avec des cellules LSTM est représenté dans la couche cachée. Image reproduite avec l'aimable autorisation de Lapalme [133, 134]

❖ **Les Blocs :** Pour les LSTM, il est important de distinguer deux concepts : les blocs et les cellules. Si le 1^{er} terme spécifie le conteneur, le conteneur qui apprend à faire entrer, sortir ou choisir de l'oublier, alors le 2^{ème} terme spécifie le contenu, la personne qui gère l'information.

Le bloc LSTM peut avoir une seule unité ou plusieurs : il leur partage uniformément les informations. Au lieu de cela, une unité appartient à un seul bloc. La fig.3.18 illustre le cas d'un bloc à 2 cellules, et la fig.3.19 illustre le cas d'un bloc à une cellule. Le bloc LSTM j a la propriété de $(3+c)$ canaux d'entrée d'informations, où c représente le nombre de cellules dans le bloc. Les canaux d'entrée d'informations sont la porte d'entrée in_j , la porte d'oubli ϕ_j et la porte de sortie out_j , ainsi que l'entrée de chaque unité. Chaque cellule de chaque bloc obtient les mêmes informations. Nous nous concentrerons sur les cellules dans la section suivante.

- *La porte d'entrée :* Lorsque sa valeur approche de zéro, cette porte empêche les informations externes d'atteindre les cellules du bloc, mettant ainsi à jour leurs valeurs. Par conséquent, les informations des couches inférieures ne sont pas transférées aux couches supérieures [133].
- *la porte d'oubli :* Lorsque sa valeur approche de zéro, la cellule oublie son passé.

- *La porte de sortie* : Elle détermine quand une cellule peut adresser une valeur à d'autres cellules (quand sa valeur est voisine de 0, la cellule ne donne pas d'information en sortie, sa valeur est voisine de 0).

Chaque porte reçoit, au pas de temps t , des informations relatives au pas de temps t de la couche d'entrée, et des informations relatives au pas de temps $t-1$ des unités de la même couche cachée. Il est important de préciser que les poids survenant à ces portes sont tous transformés lors de l'apprentissage. Cela signifie que chaque bloc apprend à reconnaître les moments où les informations externes doivent être prises en compte et quand il doit communiquer avec le monde extérieur. Notez également que les portes de sortie susmentionnées n'appartiennent pas au modèle d'origine. Ils ont été proposés par Gers et al. [135] et a été proposé dans la plupart des implémentations pour améliorer les performances.




Fig. 3.19. Une cellule LSTM équipée d'un bloc est représentée, elle-même équipée d'une cellule.

Image extraite de Gers et al. [135].

❖ **Les cellules** : Une cellule c , appartient à un bloc j , numéroté v , que nous noterons c_j^v , possède également une voie d'entrée et une voie de sortie (en plus des 3 voies reliées à 3 portes).

En plus, chaque cellule a une unité de calcul linéaire, appelée « Constant Error Carousel » ou "Constant error carousel" en anglais (CEC), dont l'activation est notée $s_{c_j^v}$. Ensuite on parle de l'état de la cellule. C'est cette unité qui résout le problème de la décroissance du gradient qui entrave l'apprentissage. En absence d'une nouvelle entrée ou d'un signal d'erreur (pendant la rétro propagation) atteignant la cellule, la rétroaction d'erreur locale du CEC (causée par des boucles cycliques) reste inchangée. Elle peut donc être maintenue sur de longs pas de temps (nous y reviendrons plus tard).

En effet, l'état de la cellule n'est pas actualisé à chaque pas de temps du fait des portes de bloc. Au niveau des informations acquises, une unité CEC prend en compte distincts modèles d'informations : informations calculées au pas de temps t (entrée de l'unité, état de la cellule $s_{c_j^v}(t)$, portes de valeurs différentes $y^{in_j}(t)$, $y^{\phi_j}(t)$ et $y^{out_j}(t)$) et les informations relatives au pas de temps $t-1$ (L'ensemble des valeurs de sortie de l'ensemble de cellules de la couche cachée $y^{c_j^v}(t-1)$ et l'état de la cellule $s_{c_j^v}(t-1)$). Cette opération en deux étapes est la performance de LSTM [133].

3.3.3. Fonctionnement d'une unité LSTM

Comme on peut le voir, une cellule LSTM est constituée de plusieurs éléments : trois portes et autant d'entrées et de sorties qu'il y a de cellules. Malgré la complexité de la structure, les performances sont toujours au rendez-vous, notamment grâce à la simplicité des calculs effectués. En fait, à l'exception de la sortie cellulaire, tous les autres composants (passerelle et entrée cellulaire) sont des neurones artificiels, qui sont appris à l'aide de la rétro propagation standard. En interne, les calculs sont des produits et des sommes, ce qui rend le tout facile à distinguer et à manipuler pour l'apprentissage. Autre façon de montrer une cellule LSTM est de la considérer comme un diagramme schématique (algorithme 1) des trois algorithmes "if then else" (pour 3 portes) décrits ci-après. Dans cette section, nous décrirons le fonctionnement de la cellule LSTM et les distinctes relations nécessaires pour cela [133].

❖ Symboles et fonctions d'activation

Tout d'abord, il est essentiel de déterminer quelques symboles :

Pour les blocs et les cellules :

- j : bloc d'une couche cachée donnée
- v : cellule dans un bloc donné

- c_j^v : cellule v du bloc j
- in_j : la porte d'entrée du bloc j
- ϕ_j : la porte d'oubli du bloc j
- out_j : la porte de sortie du bloc j
- $s_{c_j^v}(t)$: état s de la cellule v du bloc j

Pour la couche de sortie réseau :

- k : neurone au niveau de la couche de sortie du réseau
- e_k : erreur calculée au niveau de l'unité k de la couche de sortie du réseau

• **Algorithme 1 :**

L'algorithme d'opération de porte est basé sur trois algorithmes "if then else".

Si Valeur porte Entrée $\gg 0$ **alors**

Ouvrir la porte : transmettre des informations externes à l'intérieur du bloc.

Si Valeur porte Oubli $\gg 0$ **alors**

État précédent du CEC affecte le calcul de l'état actuel.

Si Valeur porte Sortie $\gg 0$ **alors**

Portes ouvertes : transmettre les informations à l'intérieur du bloc vers l'extérieur.

Sinon

Les portes sont fermées : Aucune information n'est fournie à la sortie.

Fin Si

Sinon

La cellule oublie son passé

Fin Si

Sinon

Porte fermée : informations bloquées.

Fin Si

- t^k : sortie (valeur) attendue au niveau de l'unité k

Autres notations :

- m : neurone connecté à la cellule LSTM.
- net_x : activation reçue par l'unité de calcul x (Qu'il s'agisse de portes, de cellules ou de neurones artificiels).
- y^m : activité de l'unité de calcul m
- $w(l,m)$: poids provenant de m et allant vers l'unité de calcul l

La section suivante justifiera trois fonctions d'activation :

- $f : x \rightarrow f(x)$: Sigmoidé, fonction logistique entre $[0,1]$ telle que

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.26)$$

- $h : x \rightarrow h(x)$: Sigmoidé centrée entre $[-1,1]$ telle que

$$h(x) = 2 * f(x) - 1 \quad (3.27)$$

- $g : x \rightarrow g(x)$: Sigmoidé centrée entre $[-2,2]$ telle que

$$g(x) = 4 * f(x) - 2 \quad (3.28)$$

On notera respectivement leurs dérivées f' , h' et g' [133].

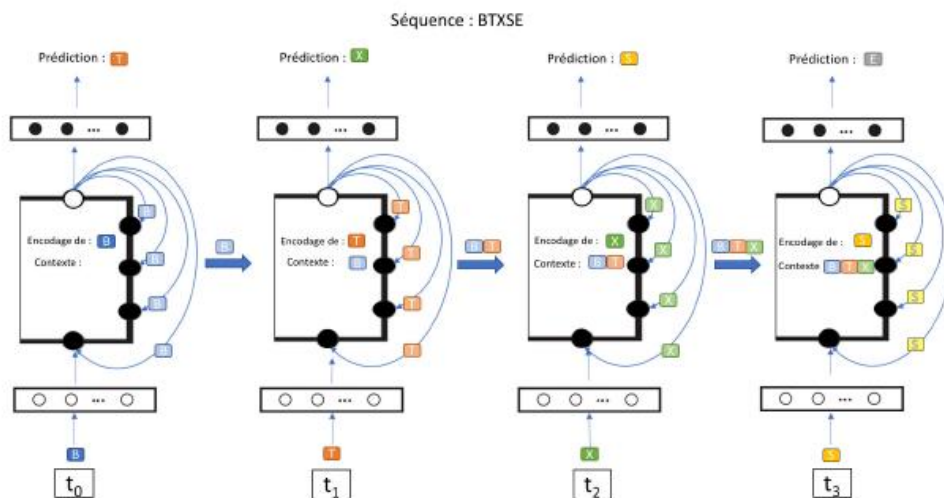


Fig. 3.20. Schéma de principe des étapes de propagation vers l'avant dans un RNN-LSTM pour l'ensemble de la séquence. Chaque symbole de la séquence est représenté par une couleur. Les symboles de couleur plus claire représentent des versions codées des symboles présentés en entrée du réseau [133].

Tableau. 3.4. Comparaison entre les méthodes de classification et de régression utilisées.

	Réseaux de neurone artificiels RNA.	Les machines à vecteurs de support SVM.	Les réseaux récurrents à mémoire court et long terme LSTM.
Avantages	<ul style="list-style-type: none"> ❖ Il peut réaliser des tâches qui ne peuvent pas être réalisées par des programmes linéaires. ❖ Lorsqu'un élément du réseau de neurones décline, il continue de fonctionner sans problème grâce à ses capacités parallèles. ❖ Il peut fonctionner dans n'importe quelle application. 	<ul style="list-style-type: none"> ❖ SVM fonctionne relativement bien lorsqu'il existe une marge de séparation importante entre les classes. ❖ Les SVM sont plus efficaces dans les espaces de grande dimension. ❖ SVM fonctionne bien lorsque le nombre de dimensions est supérieur au nombre d'échantillons. 	<ul style="list-style-type: none"> ❖ Les LSTM sont bien meilleurs pour gérer les dépendances à long terme. Cela est dû à leur capacité à conserver les informations pendant une longue période. ❖ Les LSTM sont beaucoup moins sensibles au problème du gradient. En effet, ils ont utilisé un type différent de fonction d'activation appelé cellule LSTM, qui aide à préserver les informations sur les longues séquences. ❖ Les LSTM sont très efficaces pour modéliser des données séquentielles complexes. En fait, ils peuvent apprendre à capturer des représentations de haut niveau des structures de données.
Inconvénients	<ul style="list-style-type: none"> ❖ Les réseaux de neurones doivent être formés pour fonctionner. ❖ Les grands réseaux de neurones nécessitent de longs temps de traitement. 	<ul style="list-style-type: none"> ❖ L'algorithme SVM n'est pas adapté aux grands ensembles de données. ❖ Les SVM ne fonctionnent pas bien lorsque le jeu de données est plus bruyant, c'est-à-dire lorsque les classes cibles se chevauchent. ❖ Dans les cas où le nombre de 	<ul style="list-style-type: none"> ❖ Ils sont plus complexes que les RNN traditionnels et nécessitent plus de données de formation. ❖ Ils ne sont pas bien adaptés aux tâches d'apprentissage en ligne. ❖ Les LSTM peuvent être lents à s'entraîner sur de grands ensembles de données. ❖ Les LSTM peuvent ne pas convenir à tous les types de données. Par exemple, ils peuvent ne pas bien gérer des données hautement non

		<p>fonctionnalités par point de données dépasse le nombre d'échantillons de données d'apprentissage, SVM fonctionnera mal.</p> <p>❖ Étant donné que les classificateurs de vecteurs de support fonctionnent en plaçant des points de données au-dessus et en dessous de l'hyperplan de classification, il n'y a pas d'interprétation probabiliste de la classification.</p>	<p>linéaires ou de grandes quantités de bruit.</p>
--	--	---	--

Conclusion

Le thème de ce chapitre est d'attirer l'attention sur les principes fondamentaux des méthodes et techniques d'apprentissage statistique appliquées à la classification et à la régression. Dans un premier temps, nous passons en revue les concepts de base des réseaux de neurones artificiels, de la méthode des machines à vecteurs de support et des réseaux récurrents à mémoire court et long terme. Des applications développées à partir de ces techniques d'apprentissage sont également présentées ci-dessous pour répondre aux critères de performance proposés et aux exigences de la chaîne de contrôle et de surveillance.

Le chapitre suivant est entièrement destiné aux simulations, dédié à l'appréciation des performances des techniques étudiées. L'objectif est d'étudier ces méthodes et de contribuer à leur application dans le domaine du contrôle de la qualité de l'eau, soit par la mise en œuvre et la conception de nouveaux capteurs (capteurs logiciels), soit par la reconnaissance de formes pour le suivi de la qualité.

L'évaluation pour les méthodes exposées dans ce chapitre et le chapitre précédant ce fera à différents scénarios: l'utilisation des cartes auto-organisatrices de Kohonen (SOFM),

classification ascendante hiérarchique (CAH) et l'analyse en composante principale (ACP) dans la sélection des caractéristiques dans un but de réduction de dimension et la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs et l'utilisation des techniques avancées de classification et de régression, telles que: la mémoire longue à court terme (LSTM), les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (RNA). Plusieurs exemples d'application sont créés dans ce cadre, la sélection des caractéristiques, le contrôle de potabilité de l'eau en tant que problème de classification supervisée, la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs par de classification automatique et la prédiction de la dose optimale du coagulant et l'indice de qualité de l'eau (IQE) par régression non linéaire. On évaluera pour les méthodes de classification et de régression exposées les paramètres liés au taux de reconnaissance, au temps d'apprentissage et à l'erreur d'entraînement.

CHAPITRE IV

SIMULATION ET ÉVALUATION

Introduction

Ce chapitre est destiné à la simulation et vise l'application des techniques étudiées comme étant une solution dans la surveillance de la qualité de l'eau par reconnaissance de formes. L'objectif est de valider et d'évaluer les performances de chacune des méthodes présentées appliquées pour la sélection des caractéristiques, la classification supervisée et non supervisée et la régression de données. Les exigences principales d'efficacité sont formulées sur deux points essentiels à savoir, les tests de spécification qui vérifient que les programmes réalisent bien les différentes tâches pour laquelle il a été conçu, et les tests de performances qui vont servir à mesurer l'efficacité avec laquelle cette tâche est remplie.

Afin de mener une étude de simulation permettant la mise en œuvre de plusieurs techniques proposées dans les différentes l'applications en question, on évaluera pour les méthodes exposées dans plusieurs parties et à différents scénarios: l'utilisation des cartes auto-organisatrices de Kohonen (SOM), classification ascendante hiérarchique (CAH) et l'analyse en composante principales (ACP) dans la sélection des caractéristiques et la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs et l'utilisation des techniques avancées de classification et de régression, telles que : mémoire court et long terme (LSTM), les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (RNA). Trois exemples d'application sont prévus dans ce cadre, le contrôle de potabilité de l'eau en tant que problème de classification supervisée, la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs par de classification non supervisée et la prédiction de la dose optimale du coagulant et l'indice de qualité de l'eau (IQE) par régression non linéaire ainsi que la sélection des caractéristiques en premier lieu à l'aide de deux techniques ACP et SOM. On évaluera pour les méthodes d'apprentissage exposées (SVM, LSTM et RNA), les paramètres liés au taux de reconnaissance, au temps d'apprentissage et à l'erreur d'entraînement.

4.1. Problématique de la surveillance et de diagnostic et les travaux connexes

Plusieurs travaux ont été employés dans la surveillance et le diagnostic des systèmes de production d'eau en Algérie. Il a été utilisé dans une variété d'applications dans le monde réel. Un utilisateur doit d'abord construire un ensemble de données d'apprentissage qui sont étiquetés afin de développer des modèles de comportement pour la surveillance, le diagnostic et le contrôle. Des méthodes de classification et de régression sont ensuite appliquées à l'apprentissage des données sélectionnées pour construire des modèles qui est ensuite utilisé pour affecter une décision souhaité. M. Ladjal et al. [1, 34] ont étudié les performances des techniques d'intelligence artificielle qui incluent le réseau de neurones artificiels, le réseau de neurones artificiels à base radiale, et la machine à vecteurs de support pour le développement d'un capteur logiciel d'oxygène dissous (OD) vu comme un problème de régression, et le contrôle de potabilité de l'eau en tant que problème de classification. La technique SVM multi-classe sélectionnée pour ses performances, est retenue pour une extension multi-classe où trois classes de la qualité de l'eau sont envisagées. Dilmi et al. [136] ont développé plusieurs modèles intelligents basés sur l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) et de techniques d'apprentissage automatique (LSTM RNN, SVM et ELM) pour améliorer la décision et le diagnostic des systèmes de production et de surveillance automatique de la qualité de l'eau propre. Ils ont utilisé des RNN LSTM et des SVM avec les trois techniques de sélection de caractéristiques. De plus, ils ont utilisés trois méthodes de validation croisée et deux méthodes de test hors échantillon pour estimer les performances du modèle LSTM RNN. D'après leurs résultats, l'intégration des RNN LSTM avec LDA et des RNN LSTM avec ICA donne une précision de 99,72 %, utilisant la technique Random-Holdout.

Durant ce travail de thèse, nous avons eu l'occasion d'aborder plusieurs axes liés à nos travaux de recherche. L'innovation de ce travail réside principalement dans l'intégration de différentes tâches principales dans un système global permettant : la surveillance, le diagnostic et le contrôle en ajoutant plusieurs tâches supplémentaires comme : La reconstruction des données, la prévision de la dose de coagulant et l'indice de qualité de l'eau potable prenant en compte le rôle d'aide à la décision. Trois parties de la thèse ont donc consistées à développer un outil permettant de décrire l'état de l'eau pour la surveillance par classification de données ou sous forme d'un indice global de la qualité de l'eau par régression, le développement d'un capteur logiciel de la dose du coagulant à injecter pour le contrôle. L'outil peut également être utilisé pour analyser et traiter des

ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants, d'excellentes comme des opérations de diagnostic par la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs. Ces approches globales utilisant les méthodes de classification et de régression comme LSTM, SVM et RNA pour la surveillance, le diagnostic et le contrôle des systèmes de production d'eau en combinaison avec les méthodes SFOM, ACP et CAH pour la sélection des caractéristiques, le regroupement, la visualisation et l'interprétation des ensembles de données non linéaires, bruyants, redondants, irréguliers ou manquants et aberrants utilisant les techniques de la validation croisée, est proposée. Les techniques d'apprentissage sont utilisées dans une étude comparative appliquées aux deux zones d'études en Algérie, pour montrer l'évaluation des performances des modèles de surveillance et pour obtenir la meilleure décision et la solution adéquate en termes de précision (apprentissage et test) et de temps d'exécution. Nous étudions le potentiel de notre approche proposée pour obtenir une représentation efficace et une réduction de la dimensionnalité à l'aide de la méthode de sélection des caractéristiques et la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs, pour l'amélioration des résultats de classification binaire et de régression non linéaire des algorithmes d'apprentissage automatique supervisés.

Il s'agit dans cette partie de travail d'évaluer les performances des techniques citées précédemment qui sont issues, rappelons-le, du domaine de l'intelligence artificielle à savoir, LSTM, SVM et RNA et les techniques de sélection des caractéristiques et de regroupement SOM, ACP et CAH. Des techniques servant comme outils de base pour l'aide à la décision. Sur la base des résultats obtenus, conduira à l'intégration de la technique sélectionnée au niveau d'un système de surveillance assurant un contrôle permanent de la qualité de l'eau. Le processus de contrôle est vu comme un problème de reconnaissance de formes, où les formes représentent l'ensemble des observations ou mesures des paramètres liés à ses caractéristiques. L'architecture de ce système imaginé est basée sur une approche multi-capteurs et présentée dans la figure 4.1.

4.1.1. Rôle de chaque bloc

- **Données d'entrée :** C'est un ensemble d'informations délivrées par les capteurs physiques installés.

- **Calcul statistique** : Le calcul concerne la collecte de données, leur traitement et leur présentation par des règles et des méthodes afin de rendre ces données exploitable et correctement interprétées.
- **Extraction des caractéristiques** : L'extraction des caractéristiques une exploration de données informatives pertinentes et non redondantes à partir d'un ensemble initial de données mesurées (caractéristiques) facilitant ainsi les étapes ultérieures d'apprentissage et de généralisation.

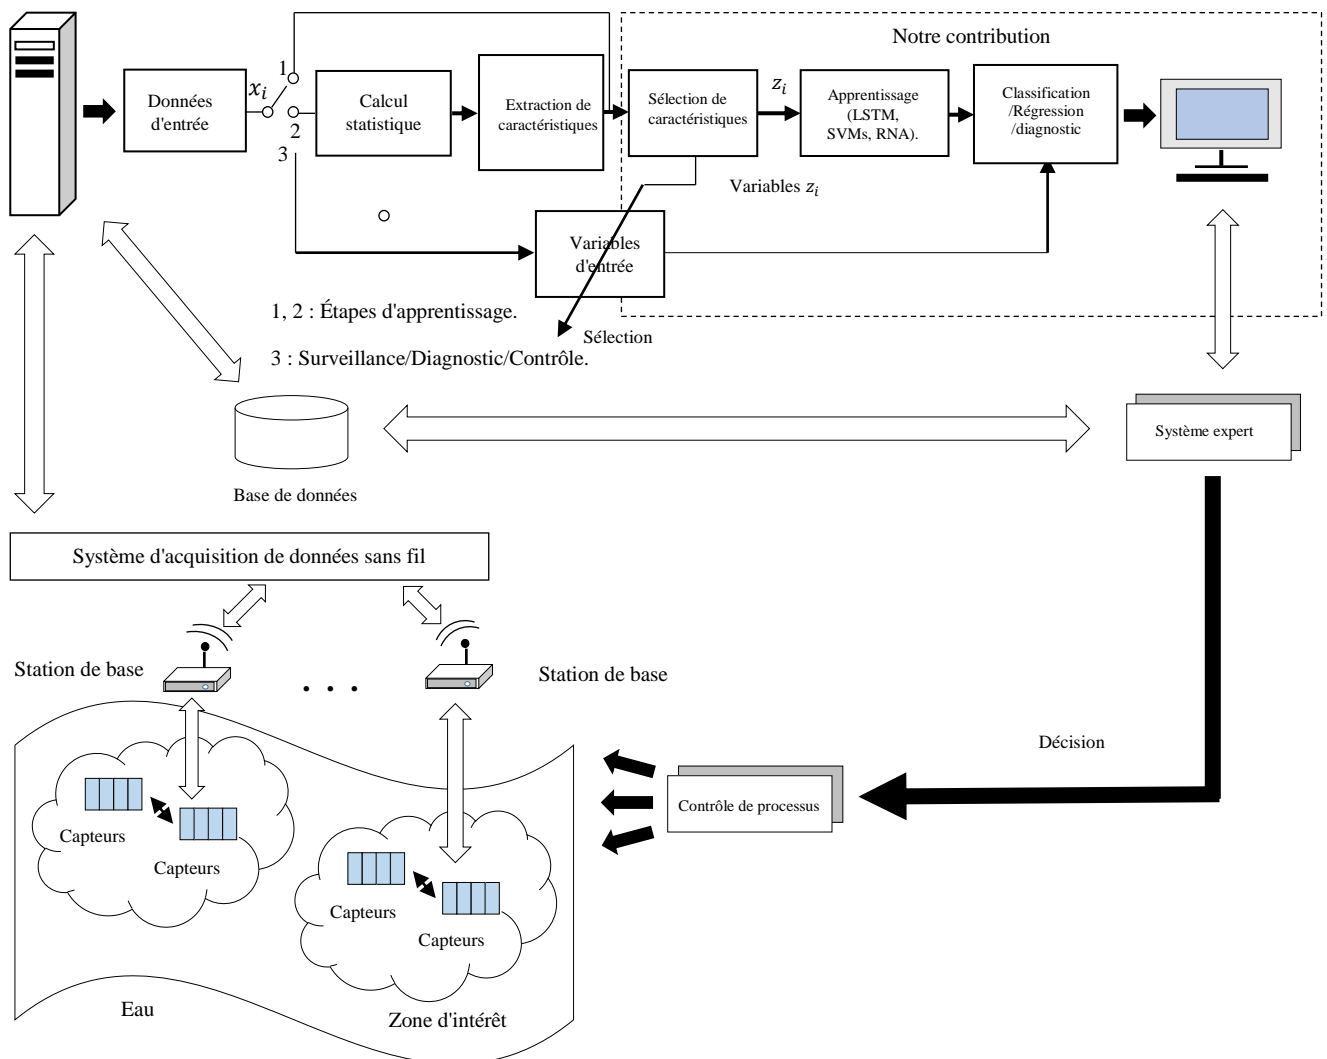


Fig. 4.1. Le système multi-capteurs de surveillance de la qualité de l'eau [34, 136].

- **Sélection des caractéristiques** : La sélection de caractéristiques ou de variables est une méthode de réduction de la dimensionnalité consiste, dans un espace de grande dimension, à trouver un sous-ensemble réduit de variables pertinentes.

- **Apprentissage** : C'est l'étape de trouver des interactions ou des relations efficaces reliant les valeurs de sortie et les valeurs d'entrée afin d'acquérir ou à modifier une représentation d'un environnement.
- **Classification** : Il s'agit d'un problème de modélisation prédictive où l'étiquette de classe est anticipée pour un exemple spécifique de données d'entrée.
- **Régression** : C'est une technique pour étudier la relation entre les variables indépendantes et leurs résultats. Elle est utilisée comme méthode de modélisation prédictive dans l'apprentissage automatique, où des algorithmes sont utilisés pour prédire des résultats continus.
- **Diagnostic** : C'est le raisonnement qui conduit à identifier la cause d'un dysfonctionnement, à partir des symptômes révélés par l'observation, l'inspection ou les tests.
- **Contrôle** : La difficulté principale est de déterminer la dose optimale de coagulant à injecter en fonction des caractéristiques de l'eau brute. Un mauvais contrôle de ce procédé peut entraîner une augmentation importante des coûts de fonctionnement et le non-respect des objectifs de qualité en sortie de la station de traitement.

Le système à base de surveillance par reconnaissance de formes de la qualité de l'eau (figure 4.1) est fondé sur une approche multi-sensorielle (réseau de capteurs) capable de qualifier l'état de l'eau à contrôler. Les différents paramètres descripteurs de l'eau devraient être transformés en signaux électriques à l'aide des capteurs qui permettent de capter et collecter les informations nécessaires, d'analyser les traitements et de transmettre les données ainsi recueillies. Ces capteurs sont déployés de manière aléatoire dans une zone d'intérêt, et une station de base située à l'extrémité de cette zone dont le rôle est d'agrèger, d'exploiter et de récupérer les données collectées. Ces informations récoltées sont supposées acheminées grâce à des communications sans fil ou directes vers une station PC de contrôle et de traitement. A ce niveau, le traitement et l'analyse des données acquises sont effectués. Le système pourrait effectuer un apprentissage hors ligne exploitant les données ainsi récoltées. La présence d'un opérateur expert est indispensable pour l'aide à la décision et l'enrichissement éventuel de la base de données ainsi constituée. Les étapes de traitement (apprentissage, classification, régression, décision etc.) assurées par le système dans le but du contrôle, de surveillance et de diagnostic du processus évoqué, constituent la part de notre contribution dans ce travail. L'objet de notre

recherche est de sélectionner après validation l'approche (sélection – apprentissage – diagnostic) la mieux adaptée. Le choix repose bien entendu sur une étude comparative permettant d'évaluer les performances de chacune des méthodes mis en examen.

4.2. Zones d'étude et données d'entrée

4.2.1. Le barrage de Tilesdit

Le barrage « Tilesdit » est situé géographiquement dans la commune de Bechloul à 20 km du Sud-Est de la wilaya de Bouira, Algérie. Il est situé entre les coordonnées cartographiques et les coordonnées Lambert suivantes (figure 4.2) : Latitude : 35° 13' 22'' Nord et Longitude : 4° 14' 23'' Est.



Fig. 4.2. Carte géographique et image montrant la région étudiée : Barrage du Tilesdit – Bouira – Algérie [Google Maps].

Le barrage a une capacité de stockage d'eau de 167 millions de mètres cube. La conception vise à atténuer les tensions d'attribution de l'eau qui persiste au niveau des 12 communes. Du fait de sa localisation dans la zone de Bouira, le barrage de Tilesdit a été saisi fin 2005. Il est destiné à alimenter en eau potable la commune de Bouira, les villes voisines (Bechloul, El-Asnam, El-Adjiba Oued-El -Derdi, Ahl-El-Ksar), les villes du sud-est (Tagdit, Oukhris, Mesdours), Ouled-Rached, Hadjr Zerga), alimentation de la zone industrielle de Sidi Khaled, irrigation autour du plateau d'El Asnam et de la vallée du Sahel.

La station de traitement de l'eau potable de la wilaya de Bouira est dimensionnée pour traiter un débit moyen d'eau brute de 1009 l/s (3632 m³/h). Elle peut traiter des eaux avec une concentration en MES jusqu'à 2000 mg/l. L'eau brute est une eau de surface soutirée du barrage « Tilesdit » dont la qualité sera vérifiée régulièrement afin que la potabilisation puisse être assurée. La qualité de l'eau traitée doit respecter les recommandations de

l'O.M.S. L'utilisation des eaux de surface s'avère nécessaire, voire indispensable, dans la mesure où les ressources souterraines traditionnelles sont insuffisantes pour répondre à la demande en eau potable.

La base de données d'entrée constituée est composée de 122 échantillons entre les années 2016 et 2018 correspondant à 11 paramètres descripteurs de la qualité de l'eau brute, qui sont : Température ($T^{\circ}\text{-}^{\circ}\text{C}$), Conductivité ($C\text{-}\mu\text{s}/\text{cm}$), pH, turbidité (TUR-NTU), oxygène dissous (DO- mg/l), magnésium ($\text{Mg}^{2+}\text{-mg/l}$), dureté totale (TH- $^{\circ}\text{F}$), dureté permanente (PEH- $^{\circ}\text{F}$), solides dissous totaux (TDS), Ammonium ($\text{NH}_4^{+}\text{-mg/l}$) et Nitrite ($\text{NO}_2\text{-mg/l}$). Des statistiques descriptives simples de ces données d'entrée sont illustrées dans le tableau 4.1. La figure 4.3 présente l'évolution temporelle de ces paramètres descripteurs

Tableau. 4.1. Mesures descriptives des paramètres de qualité de l'eau utilisée-Tilesdit [137].

Variables	Minimum	Maximum	Moyenne	Ecart type
pH	7,32	8,36	7,87	0,18
Conductivité	515,00	605,00	568,59	33,47
Température	9,80	16,00	12,16	1,28
Turbidité	2,81	10,40	4,93	1,81
Magnésium	7,29	47,63	22,69	5,16
Dureté Totale	122,00	326,00	215,14	24,09
Ammonium	0,00	0,49	0,13	0,11
Nitrite	0,00	0,46	0,07	0,08
Solides Totaux Dissous	287,00	303,00	294,19	4,48
Oxygène dissous	3,28	5,75	4,31	0,53
Dureté permanente	0,00	168,00	31,49	22,37

4.2.2. Le barrage de Cheliff

Le barrage du Cheliff est géographiquement situé à environ 30 km au nord-est de la ville de Mostaganem (figure 4.3) et à 363 km au nord-ouest d'Alger. Il est situé entre les coordonnées suivantes : $35^{\circ} 59' 00'' \text{ N}$, $0^{\circ} 24' 47'' \text{ E}$. Mostaganem a un climat semi-aride froid et une précipitation moyenne d'environ 347 mm/an. La température moyenne annuelle est de $17,9^{\circ}\text{C}$.

Le volume du réservoir a été évalué en 2009 à 50 millions de m^3 et couvre une superficie supérieure à 12 km^2 et une hauteur maximale atteint 26 mètres. Il est construit sur la rivière Cheliff. Il doit fournir annuellement 110 millions de m^3 d'eau aux wilayas de Mostaganem et d'Oran. Il se compose d'une structure en béton et d'une aile en remblai. L'eau issue du barrage est d'abord prétraitée dans une station de décantation d'une capacité de 820 800 m^3/j et doit avoir pour fonction d'alimenter en eau le barrage de Kerrada et en même temps l'eau brute est acheminée vers la station de traitement des eaux de Sidi

Lahdjel qui assure la distribution d'eau potable aux communes environnantes de Mostaganem, Arzew et Oran. Il effectue le processus de purification à travers les cinq niveaux de traitement : prétraitement, pré-oxydation, clarification, désinfection et raffinage.

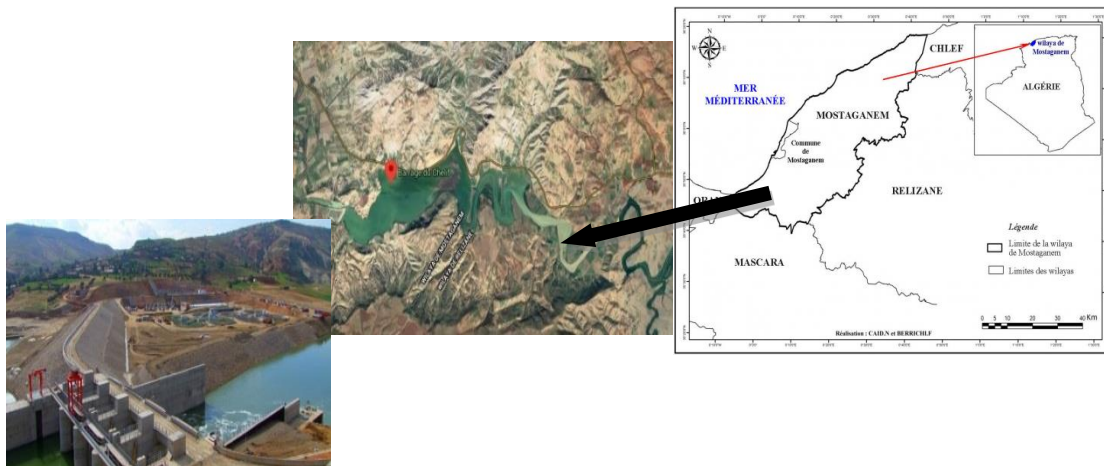


Fig. 4.3. Carte géographique et image montrant la région étudiée : Barrage du Cheliff – Mostaganem – Algérie [Google Maps].

La base de données d'entrée constituée est composée de 384 échantillons correspondant à 15 paramètres descripteurs de la qualité de l'eau brute, qui sont : Couleur, Température ($T^{\circ}\text{-}^{\circ}\text{C}$), Conductivité ($C\text{-}\mu\text{s/cm}$), pH, turbidité (TUR-NTU), Solides dissous totaux (TDS-mg/l), matières organiques (OM- mg/l), Chlore (mg/l), Bicarbonate (mg/l), magnésium (mg/l), Calcium (mg/l), dureté totale ($^{\circ}\text{F}$), Titre Alcalin Complet ($^{\circ}\text{F}$), Test de chlore et le coagulant (mg/l). Des statistiques descriptives simples de ces données d'entrée sont illustrées dans le tableau 4.2. La figure 4.3 présente l'évolution temporelle de ces paramètres descripteurs [138, 139] :

Tableau. 4.2. Mesures descriptives des paramètres de qualité de l'eau utilisée – Cheliff

Variables	Minimum	Maximum	Moyenne	Ecart type
Couleur	11	169	58.1	36.1473
Turbidité	0.66	21.7	6.5	4.2521
pH	6.25	8.37	7.97	0.2692
Température	11.3	29	19.58	4.9852
Conductivité	1144	3600	2125.6	408.1714
Solides dissous totaux	689	1728	1208.2	206.1315
Matières organiques	2.47	6.7	2.47	0.9347
Chlore	192	724	425.29	99.3793
Bicarbonate	83	299	160.02	35.6523
Calcium	59	163.5	127.2	22.0475
Magnésium	44	110	74.1	11.1634
Dureté totale	45	77	62.33	7.4717
Titre Alcalin Complet	6.8	19	13.08	2.7888
Test de chlore	0.12	4.84	1.16	0.9462
Coagulant	1.2	12	3.81	2.4355

4.3. Approche utilisée dans la surveillance et diagnostic

Cette partie est basée essentiellement sur deux opérations majeures et qui sont : l'extraction et la sélection des caractéristiques et la décision par classification ou régression. Parmi les techniques d'IA utilisées, on trouve : la mémoire longue à court terme (LSTM) et les machines à vecteurs de support (SVM) et les réseaux de neurones artificiels (RNA). Celles-ci se démarquent des autres outils par leur capacité d'apprentissage et de généralisation, notamment dans les applications de grande dimension. Ces techniques peuvent être utilisées en raison de leurs robustesses et de leurs capacités à tenir en compte de la nature dynamique et complexe du procédé. Ces techniques sont de plus en plus acceptées dans l'industrie de production d'eau potable en tant qu'outil de modélisation et de contrôle de procédés.

Le processus de classification est une étape nécessaire pour surveiller la qualité de l'eau, ce qui rend la préparation des entrées de données essentielle et nécessitant un traitement particulier dans le but d'assurer une bonne décision et une bonne performance de la décision. L'utilisation de la sélection des caractéristiques des entrées de données sans aucune transformation a attiré une attention considérable vue les avantages issus de cette sélection et qui mènent à réduire la quantité de données et du temps d'exécution pour l'atteinte de la phase d'apprentissage, à éviter la redondance, en réduisant les capteurs dans le système de surveillance, à faible coût, et à améliorer la précision de la décision.

De nombreux paramètres du procédé peuvent être mesurés en continu à l'aide de capteurs physiques relativement simples et peu onéreux. A l'opposé, la détermination de certaines quantités exige des analyses de laboratoire coûteuses qui ne peuvent être exécutées en ligne [9]. En effet, et pour de nombreuses raisons, il est souvent indispensable de disposer de ce qu'on appelle « capteurs logiciels (ou softsensors, en anglais) », dont la fonction consiste à fournir à l'utilisateur une information complexe non observable directement, telle qu'un paramètre physico-chimique non mesurable en continu (ou à un coût prohibitif), sous forme d'un indice global de la qualité de l'eau. Ces informations sont ensuite utilisées comme des données d'entrée dans la procédure de diagnostic de la partie amont d'une station de production d'eau potable. La construction d'un capteur logiciel peut être vue aussi comme un problème d'apprentissage de relations entre variables à partir de données observées. Ils sont spécialement programmés avec des algorithmes dérivés de l'intelligence artificielle. Le problème devient dans ce cas-là, comme un problème de régression.

Le but de cette étude est d'établir des modèles d'aide à la décision pour le diagnostic et la surveillance avancée de la qualité de l'eau à travers les capteurs physiques installés pour l'acquisition de données. Généralement, ce système avancé comprend le matériel et les logiciels informatiques particuliers, tels que : les capteurs, les circuits de conditionnement, l'acquisition de données, la communication sans fil, les blocs de traitement du signal pour les grands ensembles de données, et être précédé d'un prétraitement des données d'entrée à l'aide d'une sélection de caractéristiques basées sur le modèle SOM préformé ou ACP, et suivi d'une décision finale en utilisant les méthodes de classification LSTM, SVM et RNA. Toutes ces étapes sont effectuées pour obtenir la solution la plus efficace en ce qui concerne l'évaluation de la qualité de l'eau.

L'approche-cadre proposée pour la surveillance intelligente de la qualité de l'eau est illustrée à la figure 4.4, qui repose d'abord sur des données d'entrée sélectionnées et réduites à l'aide d'un modèle SOM préformé comme exemple et des méthodes d'apprentissage sont formés pour traiter les ensembles de données sur la qualité de l'eau. De plus, nous affinons de manière itérative notre modèle de reconnaissance avec de nouvelles données. Le processus de décision utilisant les méthodes d'apprentissage est effectué.

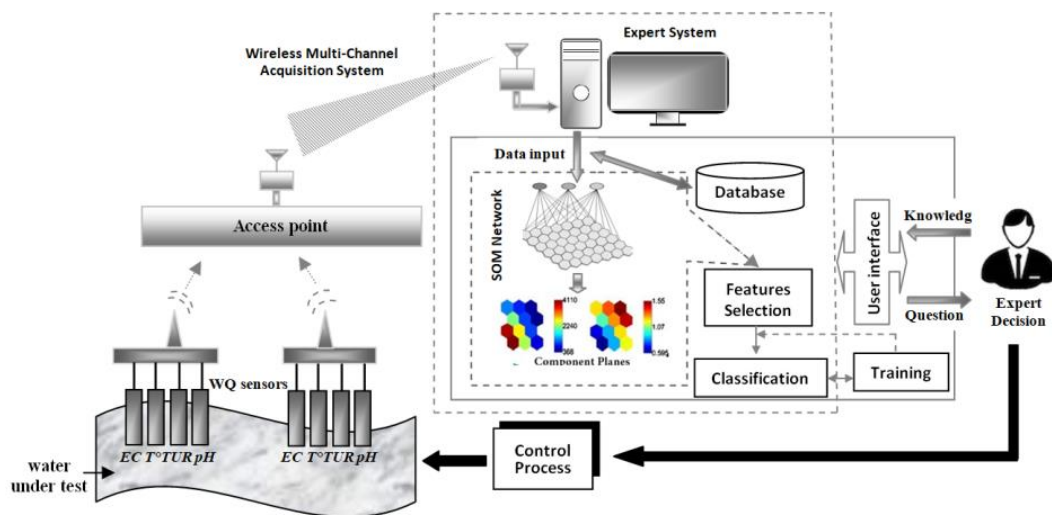


Fig. 4.4. Le cadre proposé pour la surveillance de la qualité de l'eau.

4.4. Résultats et discussion

Dans cette étude, le cadre proposé ci-dessus a été appliqué aux données sur la qualité de l'eau des stations de deux barrages : *Tilesdit* à Bouira et *Cheliff* à Mostaganem. Pour tester l'applicabilité de la méthodologie suggérée, notre modèle de surveillance se compose de

deux étapes : la sélection des caractéristiques et la décision de la reconnaissance de la qualité de l'eau. La technique de sélection des caractéristiques est basée sur ACP ou SOM et la technique de décision par classification et régression est basée sur LSTM, SVM et RNA. Le matériel utilisé pour effectuer nos expériences de simulation est le suivant : nous avons utilisé un processeur Intel Core TM i7-6820HQ et 2,71 GHz avec 8 Go de mémoire. Toutes les méthodes proposées ont été mises en œuvre et évaluées à l'aide du logiciel d'environnement MATLAB2019b avec le système d'exploitation Windows 10 (64 bits).

4.4.1. Sélection des caractéristiques

La sélection des caractéristiques pour la réduction de la dimensionnalité est une étape couramment utilisée dans l'apprentissage automatique pour garantir une bonne décision, de bonnes performances et un haut niveau de capacité de traitement du modèle ajusté. La première analyse est le processus de sélection d'un sous-ensemble de variables pertinentes et non corrélées à l'aide de l'ACP et SOM pour déterminer les données d'entrée pour les modèles de reconnaissance proposés. De plus, nous pouvons comprendre qu'il y a un changement des caractéristiques des données vers des composants qui ne sont pas corrélés. Dans l'apprentissage automatique, l'espace de caractéristiques réduit est généralement effectué en construisant un sous-ensemble des nouvelles dimensions à l'aide des méthodes ACP et SOM.

A. Réduction de dimension par SOM

Les cartes auto-adaptatives, cartes auto-organisatrices ou cartes topologiques forment une classe de réseau de neurones artificiels fondée sur des méthodes d'apprentissage non supervisées. Elles sont souvent désignées par le terme anglais self organizing maps (SOM), ou encore cartes de Kohonen du nom du statisticien ayant développé le concept en 1984. La littérature utilise aussi les dénominations : « réseau de Kohonen », « réseau auto-adaptatif » ou « réseau auto-organisé ». SOM dans de nombreuses études montrent que la méthode peut surpasser les autres méthodes de sélection des caractéristiques clairsemées en termes de capacité de classification et de regroupement et de sélection optimale des entrées de données. Dans l'apprentissage automatique, l'espace de caractéristiques réduit est généralement effectué en construisant un sous-ensemble des nouvelles dimensions à l'aide de la méthode SOM. Les cartes de caractéristiques auto-organisées de Kohonen (SOM) sont une sorte de modèle de réseau de neurones non linéaire pour l'analyse de données multi variées. Le SOM est une cartographie préservant la topologie de l'espace de

données d'entrée R^n sur un réseau bidimensionnel régulier ou hexagonal de nœuds comme une technique de réduction de dimensionnalité. A cette étape, la base de données provenant de la station Tilesdit est utilisée dans cette partie de ce travail (Figure 4.5, Tableau 4.1) ;

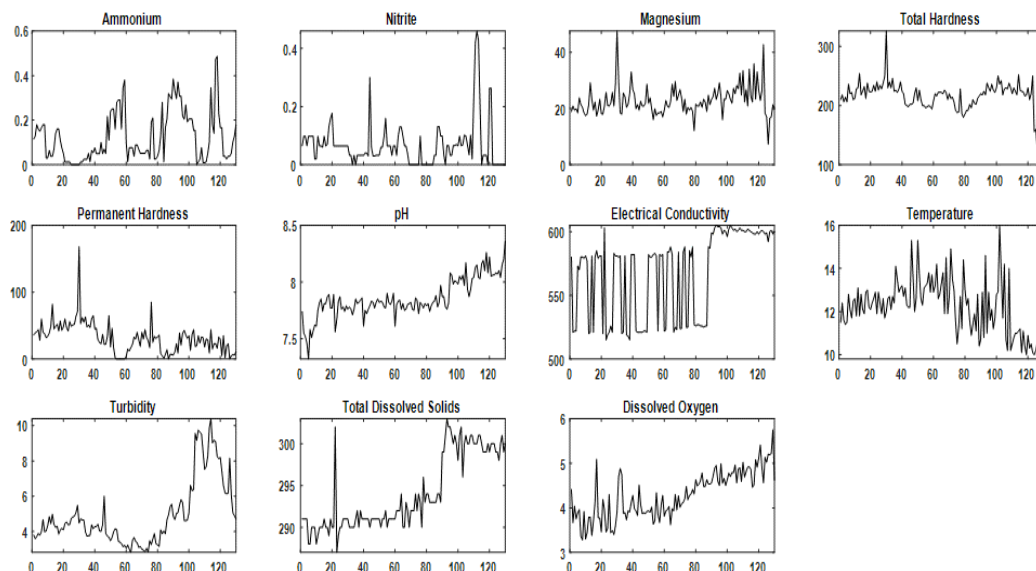


Fig. 4.5. Partie évolution des variables de qualité de l'eau – Barrage Tilesdit.

L'approche proposée de sélection des caractéristiques est utilisée pour identifier la corrélation et la similarité des paramètres de données d'entrée en utilisant la puissance de visualisation et le regroupement de SOM. Dans l'étape expérimentale, un $[6 \times 10]$ SOM composé de 60 unités (neurones) est utilisé pour la sélection des caractéristiques. En raison de la propriété de préservation topologique de SOM, les paramètres de données d'entrée qui sont très proches les uns des autres sont mappés sur les mêmes neurones ou ses voisins disposés sur le réseau de cartes. La distance entre le vecteur de référence ou prototype du neurone et ses voisins est calculée par U-matrix (la matrice de distance unifiée). La figure 4.6 visualise en utilisant une échelle de couleurs, la distribution de toutes les variables ou plans de composants sur le SOM pour les vecteurs de données d'entrée et les distances vectorielles de référence entre les nœuds dans le plan de la matrice U [137]. La plus grande distance est tracée en jaune. Par exemple, les objets avec des valeurs élevées pour l'oxygène dissous sont situés dans la partie carrément du plan SOM. Le plan des composants donne visuellement des informations sur la relation entre un paramètre et les clusters. Les paramètres tels que : conductivité, TDS et oxygène dissous passent de petites valeurs (zone inférieure gauche) à de grandes valeurs (zone inférieure droite) sur la carte. Le pH avait une graduation de la couleur presque trop claire portant les valeurs supérieures à droite. Afin de regrouper les unités SOM formées, il est avantageux d'utiliser l'algorithme

U-Matrix qui a conduit à l'identification de 3 clusters situés à gauche, au centre et à droite. Cependant, il est difficile de reconnaître définitivement l'influence des indicateurs à partir des plans composants.

La sélection du sous-ensemble des plans composants (Figure 4.7) à l'aide de SOM montre quatre groupes différents de variables [137]. Le premier sous-groupe est formé par les paramètres suivants : Ammonium, Nitrite et Turbidité. Le deuxième groupe de sous-ensembles comprend les paramètres tels que : la dureté totale, la dureté permanente, le magnésium et la température. Le troisième groupe de sous-ensembles est formé par les paramètres tels que : Conductivité, Solides dissous totaux et Oxygène dissous. Le dernier groupe est constitué par le pH. À l'aide des plans de classement, une sélection appropriée des paramètres de qualité de l'eau de surface pourrait être effectuée. Chaque groupe bien défini pourrait être sélectivement présenté par l'un de ses membres. Ainsi, la turbidité et la conductivité ont été sélectionnées pour représenter respectivement le premier et le deuxième groupe. La conductivité a été choisie pour représenter le troisième groupe. La dernière variable pH sélectionnée représente le quatrième groupe. Les paramètres de qualité de l'eau sélectionnés pourraient être déterminés analytiquement de manière plus fiable et précise et sont directement liés à des influences anthropiques spécifiques le long du bassin versant du barrage.

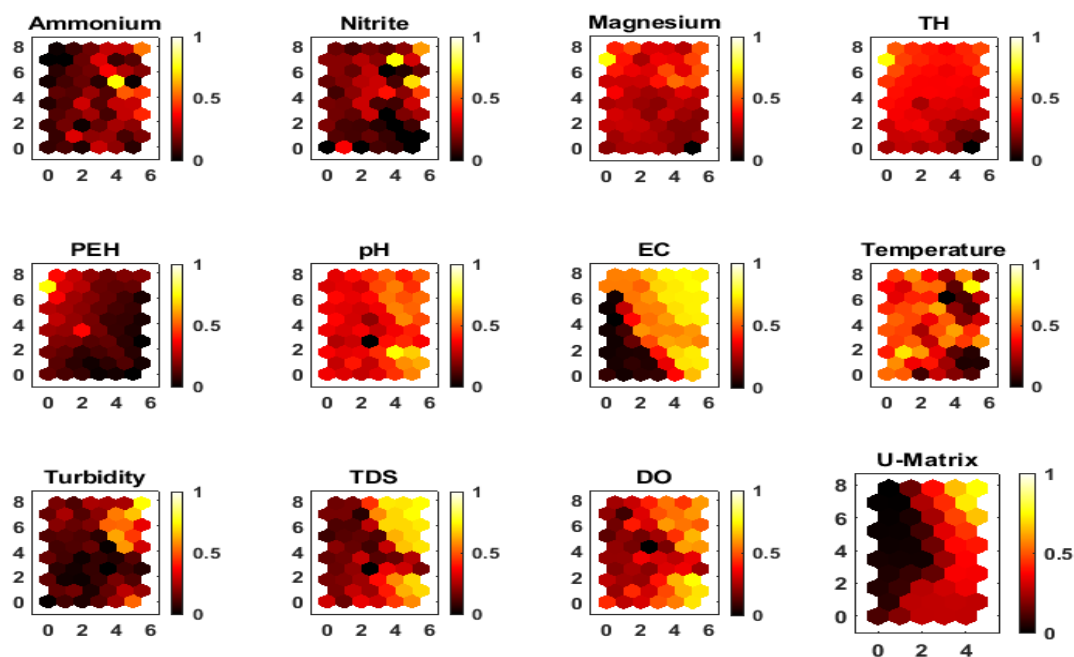


Fig. 4.6. Visualisation des plans variables (CP) et de la matrice U pour les données d'entrée affichées sur SOM – Barrage Tilesdit.

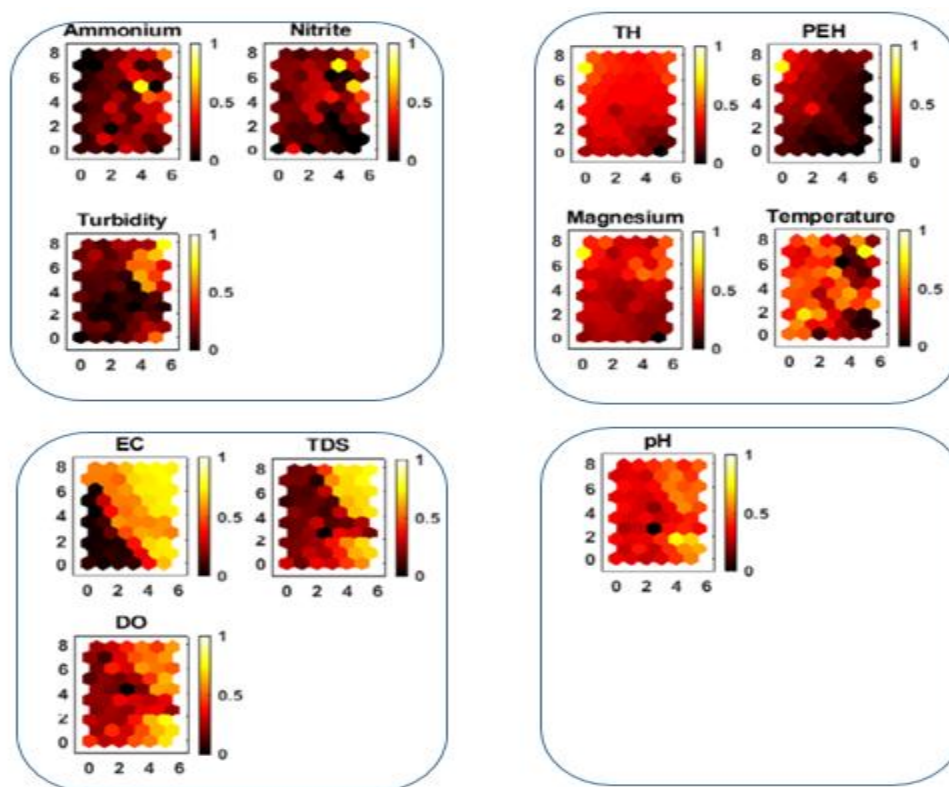


Fig. 4.7. Visualisation des plans variables sélectionnés par SOM– Barrage Tilesdit.

En présence de paramètres chimiques non mesurables en continu. Ainsi les variables retenues sont : *Conductivité (EC)*, *Température (T°)*, *Turbidité (TU)* et *pH*. Les quatre paramètres sont sélectionnés comme entrée des modèles de surveillance proposés qui sont plus facilement mesurés en continu. L'objectif est de prédire l'état de la qualité de l'eau à partir de variables sélectionnées non corrélées (*Température (T°)*, *pH*, *Conductivité Electrique (EC)* et *Turbidité (TU)*) avec un système à coût global inférieur et de meilleure qualité [137].

A cette étape, la base de données provenant de la station Cheliff est aussi utilisée dans cette partie de ce travail (Tableau 4.2) [138, 139]. La sélection du sous-ensemble des plans composants (Figure 4.8) à l'aide de SOM montre quatre groupes différents de variables.




Fig. 4.8. Visualisation des plans variables (CP) et de la matrice U pour les données d'entrée affichées sur SOM – Barrage Cheliff.

La sélection du sous-ensemble des plans composants (Figure 4.8) à l'aide de SOM montre quatre groupes différents de variables. Le premier sous-groupe est formé par les paramètres suivants : Couleur, Turbidité, MO, Test Chlore, FTA, Bicarbonate. Le deuxième sous-groupe comprend les paramètres tels que : Conductivité, TDS, Chlore, Calcium, Dureté. Le troisième groupe de sous-ensembles est formé par les paramètres tels que : Température et Magnésium. Le dernier groupe est constitué par le pH [138, 139]. Les paramètres de qualité de l'eau sélectionnés pourraient être déterminés analytiquement de manière plus fiable et précise et sont directement liés à des influences anthropiques spécifiques le long du bassin versant du barrage [137, 138, 139].

En présence des paramètres chimiques qui sont non mesurables en continu. Alors les variables retenues sont : *Conductivité Electrique (EC)*, *Température (T°)*, *Turbidité (TU)* et *pH*. Les quatre paramètres sont sélectionnés en entrée des modèles de surveillance proposés qui sont plus facilement mesurés en continu et qui sont les mêmes paramètres réduits et utilisés sur le terrain à l'aide des capteurs directement installés à chaque étape de la station de production de barrage Tilesdit [137, 138, 139].

Cette solution n'est de toute façon pas définitive pour les deux bases de données, il sera probablement nécessaire d'effectuer un système de réapprentissage périodique pour tenir compte des situations susceptibles d'être rencontrées et permettre une adaptation continue de celui-ci aux éventuelles évolutions de la qualité de l'eau. Les deux ensembles de

données décrites par les quatre paramètres de qualité de l'eau sélectionnés a ensuite été soumis à un traitement chimiométrique par des approches d'apprentissage statistique [34, 136, 137, 138, 139].

B. Réduction de dimension par ACP

Dans cette partie, nous cherchons à développer notre approche cadre de contrôle et de surveillance de la qualité de l'eau à l'aide de plusieurs descripteurs fournis dans une usine de production d'eau par certains capteurs physiques. Ces paramètres sont collectés depuis l'usine de production de Tilesdit, l'une de deux bases de données utilisées auparavant. Pour la sélection des caractéristiques des données, la méthode ACP est utilisée avec une variation de 80 à 90 % des valeurs propres, sans aucune transformation des composants résultants qui ne sont pas corrélés [7]. Au total, 1800 échantillons (après avoir sélectionné les paramètres, les mesures de ses derniers se prennent trois fois par jours et cela contraste avec le prélèvement des paramètres chimiques qui nécessite un laboratoire et ça prend de temps, alors notre base de données sera élargie à 1800 échantillons) de huit paramètres physico-chimiques de la qualité de l'eau sont utilisés dans cette phase. Les paramètres tels que le pH, la température (T°), la conductivité électrique (EC) et la turbidité (TU) sont collectés par des capteurs installés dans tous les processus de traitement de la station. Chaque semaine, au laboratoire, certains paramètres chimiques sont examinés tels que : le magnésium (Mg), le bicarbonate (B), la dureté totale (TH) et le titre alcalin complet (FTA). Les données collectées susmentionnées seront appliquées pour vérifier le modèle d'évaluation de la qualité de l'eau.

Dans un premier temps, une analyse par ACP est effectuée afin de déterminer les paramètres descripteurs ou variables d'entrée les plus représentatives de la qualité de l'eau. Il s'agit d'extraire les informations pertinentes tels que : matrice de corrélation, histogramme des valeurs propres et cercle de corrélation. A souligner toutefois, que l'ensemble des 8 variables d'entrée de cette base de données est retenu en raison de l'importance de ses paramètres pour la qualité de l'eau et la continuité de leurs mesures dans le temps. L'Analyse par ACP appliquée à l'ensemble des données de la base, fourni le tableau 4.3.

Une matrice de variance-covariance est formée en utilisant l'ACP sur les variables d'entrée. D'après Le tableau 4.3 présente les résultats de l'ACP et les paramètres statistiques tels que les valeurs propres, la proportion de variance cumulée et la proportion

de variance. Les quatre PC indiquent 84,68 % de la proportion de variance totale des échantillons d'entrée et éliminent les composants restants, comme indiqué dans le tableau 4.3 ces PC calculent principalement la variance initiale des données.

De plus, les applications ICP sont utilisées pour obtenir des vecteurs propres afin d'évaluer les coefficients pour l'apprentissage des PC. Les corrélations entre chaque variable et les principales composantes acquises sont présentées dans le tableau 4.3. Dans ce tableau, les paramètres les plus efficaces dans la formation des PC sont exposés en caractères gras. La variance totale dans l'ensemble de données représente 84,68 % des quatre premières composantes principales réunies. La première composante (PC1) est de 32,07 %, 27,93 % étant la deuxième composante (PC2), 14,05 % étant la troisième composante (PC3) et 10,63 % de la variance totale étant la quatrième composante (PC4). En général, les concentrations EC, B et FTA sont manifestement les plus efficaces pour PC1 et représentent plus de 32 % des proportions de variance des variables d'entrée. De plus, les concentrations de T° et TH ont également le plus d'effet sur le PC2, qui contient plus de 27 % des proportions de variance des variables d'entrée. De plus, les concentrations de TU et de pH sont respectivement affectées par le PC3 et le PC4 [140, 141].

Tableau 4.3. Statistiques descriptives des principaux composants créés.

	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8
	Eigenvalues							
	2.57	2.23	1.12	0.85	0.57	0.33	0.27	0.06
	Total variance proportion (%)							
	32.07	27.93	14.05	10.63	7.16	4.10	3.32	0.74
	Cumulative variance proportion (%)							
	32.07	60.00	74.05	84.68	91.84	95.93	99.26	100
	Variables of eigenvectors obtained by applying PCA							
pH	-0.57	-0.46	-0.25	0.52	-0.08	0.29	0.20	0.00
EC	0.74	0.30	-0.37	0.08	0.26	0.33	-0.21	0.00
T°	-0.04	0.78	-0.10	-0.45	-0.28	0.22	0.22	0.00
TU	-0.26	-0.47	0.73	-0.27	0.07	0.29	-0.10	0.00
Mg	0.38	0.48	0.43	0.48	-0.44	0.03	-0.13	-0.01
B	0.87	-0.41	0.11	-0.03	0.01	0.01	0.20	-0.17
TH	-0.03	0.70	0.42	0.27	0.46	-0.02	0.20	0.02
FTA	0.85	-0.45	0.09	-0.00	-0.07	-0.01	0.16	0.17

Dans le tableau 4.3, la décroissance rapide des valeurs propres est apparente. Pour évaluation des processus physico-chimiques prédominants, les valeurs propres des quatre premières composantes principales (PC1-PC4) peuvent être utilisées [142, 143]. Les concentrations EC, B et FTA sont très positives (0,74 – 0,87), tandis que la concentration de Mg est faiblement positive pour le premier composant (0,38). T° et TH ont des charges

positives élevées dans le PC2 (0,70 - 0,78), et les autres concentrations montrent des charges positives faibles (0,3 - 0,48). Les concentrations de TU dans le PC3 ont des charges positives élevées (0,73), tandis que les concentrations de FTA ont de faibles charges positives (0,09). Les concentrations de pH pour le PC4 montrent des charges positives élevées (0,52), tandis que le Mg affiche des charges positives modérées (0,48), et TU et TH montrent des charges positives faibles (0,08 - 0,27) [140, 141].

D'après le tableau 4.3, les quatre premiers PC sont les caractéristiques d'entrée des classificateurs évalués. Les variables retenues sont : pH, Température (T°), Conductivité Electrique (EC) et Turbidité (TU). En conséquence, la surveillance doit avoir lieu à la station d'épuration et de manière continue en utilisant des paramètres sélectionnés qui sont les plus représentatifs utilisés en raison des fortes corrélations existantes entre tous les paramètres, ainsi que les plus fondamentaux et facilement mesurables par des capteurs physiques dans le système de surveillance de la qualité de l'eau. Dans tous les cas, cette solution n'est pas définitive, un système de réapprentissage devrait probablement être mené périodiquement afin que les situations qui pourraient survenir soient prises en compte et ajustées en permanence pour faire évoluer la qualité de l'eau.

4.4.2. Approche de surveillance de la qualité de l'eau par classification

La surveillance de la qualité de l'eau joue un rôle important dans la gestion de l'environnement dans la plupart des pays du monde. L'utilisation rationnelle et la protection de cette ressource présente sans doute un intérêt considérable. Toutefois, les méthodes utilisées traditionnellement souffrent d'un handicap dû à la non-linéarité et la complexité des relations entre les variables de surveillance et l'état de la qualité de l'eau. On peut dire qu'il n'y a pas de méthode générale acceptée à ce jour. Certaines méthodes sont généralement employées dans plusieurs travaux pour évaluer l'état de la qualité de l'eau [144-149]. Toutefois, les réseaux de neurones artificiels souvent considérés comme une solution incontournable aux problèmes de modélisation de processus non linéaires, sont plus sollicités [150]. D'ailleurs, plusieurs travaux de contrôle et d'évaluation de la qualité de l'eau se basant sur ce type de méthodes, ont été élaborés [150, 151].

Les méthodes LSTM et SVM comme les réseaux neuronaux ont été aussi largement utilisée pour résoudre des problèmes de classification et de régression dans plusieurs domaines d'application. Dans notre application de contrôle de la qualité dans la première

partie de cette thèse ; la classification est la technique de contrôle utilisée pour la surveillance de la qualité de l'eau.

Dans ce qui suit, nous présentons la combinaison des méthodes ACP et SOM avec les méthodes LSTM et SVM, et ce toujours dans le but du contrôle et de surveillance de la qualité de l'eau. L'ACP et SOM sont utilisés pour réduire la dimension des variables d'entrée pour en extraire celles qui sont pertinentes et non redondantes. Les méthodes LSTM et SVM restent plutôt utilisées et appliquées pour le même objectif, à savoir, la classification. Pour cette nouvelle situation, il s'agit d'une classification binaire où la sortie peut appartenir à deux classes bien différentes (classe I : potable, classe II : non potable).

A. Apprentissage et classification

Dans cette section, nous allons évaluer la qualité de l'eau à partir des paramètres physico-chimiques sélectionnés. A signaler toutefois que cette base de données est réalisée selon les normes de potabilité recommandées [152, 153], deux classes de qualité de l'eau ont été considérées : (Classe I : potable, Classe II : non potable). Pour procéder aux tests, deux bases d'apprentissage et de test constitués de données réelles relatives aux différents états qualitatifs de l'eau sont utilisés. Les données d'apprentissage de 1800 échantillons du barrage Tilesdit ont été collectées du 1er janvier 2016 au 31 décembre 2018, toutes constituées des quatre variables physico-chimiques réduites par ACP et SOM, qui sont : Température (T°), pH, Conductivité, Electrique (EC) et Turbidité (TU).

A.1. Evaluation des performances

Les paramètres de performances, tels que : *le taux de classification* (ACC : le pourcentage de prédictions qui sont correctes), *la sensibilité* (Recall, Se : taux de vrais positifs), *la spécificité* (Sp), la précision (Pr : valeur prédictive positive), *le score F* (F-Scr) et le temps d'entraînement (T_train) ont été utilisés pour évaluer des performances de deux modèles proposés LSTM et SVM. Les mesures des performances sont calculées par les équations suivantes [154, 155] :

$$\text{Acc (\%)} = \frac{\text{nombre de classifications correctes}}{\text{nombre total d'échantillons d'essai}} \quad (4.1)$$

$$\text{Pr} = \frac{TP}{TP + FP} * 100\% \quad (4.2)$$

$$Se = \frac{TP}{Pr \frac{TP}{TP + FN}} \quad (4.3)$$

$$Sp = \frac{TN}{TN + FP} * 100\% \quad (4.4)$$

Le vrai positif (TP) et le vrai négatif (TN) correspondent à des échantillons correctement classés de chaque classe, tandis que les faux positifs (FP) et les faux négatifs (FN) correspondent respectivement à des échantillons mal classés.

A.2. Mise en œuvre du modèle LSTM

Pour évaluer les méthodes proposées, une validation croisée standard de *k-Fold* avec $k = 10$ et un simple Holdout ont été mis en œuvre dans les phases d'apprentissage et de test. Pour valider la capacité de généralisation des modèles proposés avec simple Holdout, les données brutes sont divisées en deux sous-ensembles : 60 % sont utilisés pour l'apprentissage et les 40 % restants sont utilisés pour les tests. Les résultats de simulation avec toutes les mesures de performances de chaque méthode proposée sont présentés.

L'architecture d'un réseau LSTM est la plus utilisée en pratique qui permet de répondre au problème de disparition de gradient. Elle est utilisée dans le domaine de l'apprentissage en profondeur (Deep learning). Une unité LSTM commune est composée d'une cellule, d'une porte d'oubli (Forget Gate), d'une porte d'entrée (Input Gate) et d'une porte de sortie (Output Gate) et gère une mémoire dynamique (notée C) qui évolue en fonction de la séquence de données temporelle. La principale idée derrière un LSTM est de diviser le signal qui traverse notre réseau en deux parties bien distinctes : Court Terme à travers le *hidden state* et Long Terme à travers le *cell state*. Le réseau utilisé pour décider sur l'état de l'eau est composé de trois couches connectées entre eux, une couche entièrement connectée (*fully connected layer*), une deuxième couche (*softmax layer*) et une couche de sortie (*output layer*). Chaque couche cachée est suivie d'une couche de suppression (*dropout layer*) implémentée entre les couches cachées et appliquée après chaque couche LSTM pour la régularisation (dropout value = 0.2). Dans cette application, différentes architectures de LSTM ont été testées pour déterminer le nombre adéquat de couches cachées et les neurones dans les couches cachées.

Le Tableau 4.4 montre les résultats associés aux modèles LSTM dans les phases d'apprentissage et de test [137]. Les paramètres, tels que : les différents mesures de

performances, la technique de sélection de caractéristiques, la précision (ACC) pour la phase de test, le temps d'apprentissage et de test. Nous appliquons une validation croisée standard *k-fold* et des procédures Holdout simples pour évaluer les mesures de performance des modèles LSTM pour la classification de la qualité de l'eau. Les résultats décrits dans ce tableau ont été obtenus en utilisant des LSTM RNN à couche unique, le nombre de neurones dans la couche cachée (Hiddnum) = 100, le nombre d'itérations = 200, la taille du lot = 27 exemples d'apprentissage, batch_size = 72.

Tableau. 4.4. Les résultats du modèle de classification LSTM dans les phases de formation et de test.

Modèles	Indicateurs de performances					
	Pr	Se	Sp	F-Scr	T_tr (s)	Acc
LSTM-Holdout (Training)	99.64%	99.02%	96.99%	99.33%	1.2863e+3	98.81%
LSTM-Kfold (Training)	100%	97.44%	100%	98.70%	936.03	97.67%
LSTM-Holdout (Testing)	99.17%	99.37%	93.44%	99.27%	0.09	98.70%
LSTM-Kfold (Testing)	100%	97.95%	100%	98.96%	0.08	98%

D'après le tableau 4.4, les deux méthodes de validation croisée utilisées présentent de très bons résultats sur le plan décisionnel. Le taux de classification utilisant k-fold est de 97.67% à 98%. Alors que le taux de classification utilisant Holdout est de 98,81 % à 98,70%. Nous pouvons observer que la validation croisée utilisant Holdout est l'approche la mieux placée pour estimer les performances de nos modèles à cause de leurs résultats qui sont meilleurs.

A.3. Mise en œuvre du modèle SVM

Les résultats d'apprentissage obtenus avec le modèle SVM utilisant la même base de 1800 vecteurs de quatre variables sélectionnés auparavant, sont présentés dans les tableaux 4.5 et 4.6. Les paramètres tels que le nombre de vecteurs de support (NVS) après apprentissage, les différentes mesures de performances (Pr, Se, Sp et F-Scr), le temps d'apprentissage (T_tr), ainsi que le taux de reconnaissance (ACC) sont tous indiqués pour différentes valeurs du facteur C , avec différentes fonctions noyaux (polynomial et RBF). Faut-il souligner que les paramètres σ et C associés au noyau RBF ainsi que d lié au degré du polynôme et γ (noyau polynomial) influent souvent sur la classification [20]. Par conséquent, une mauvaise sélection des paramètres C , σ et d peut entraîner un problème de sur-ajustement ou de sous-ajustement dans le processus de classification.

L'objectif est d'identifier le choix optimal de ces paramètres afin que le classificateur puisse classer avec précision les données d'entrée à l'aide de la validation croisée *k-fold*. Toutes les paires de (C, σ) pour le noyau RBF et (d, C, γ) pour le noyau polynomial sont testées et choisies avec une meilleure précision utilisant la validation croisée.

Dans les tableaux 4.5 et 4.6, les taux de reconnaissance avec l'utilisation de la sélection des caractéristiques par SOM et ACP variaient de 98,10 % à 99,75 % dans la phase d'apprentissage et de 96,67 % à 99,81 % dans la phase de test [137]. Le taux de reconnaissance d'apprentissage utilisant un noyau linéaire est généralement inférieur à celui des noyaux RBF gaussien et polynomial. Pour le modèle SVM, les performances du processus de classification sont augmentées en raison de la sélection des caractéristiques, car SOM ou ACP recherche les composants non corrélés à partir de l'espace de données d'entrée et les traite de manière à ce qu'ils soient plus utiles dans la classification.

Par conséquent, l'effet de la sélection des fonctions du noyau et de ses paramètres C et σ ou d et γ est très important pour obtenir de bonnes performances dans les ensembles d'apprentissage et de test et il n'y a pas de règles définies régissant son choix qui pourraient donner une performance satisfaisante. En effet, la performance dépend du choix de ces paramètres par l'utilisation de processus d'optimisation via des méthodes de validation croisée.

Tableau. 4.5. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de formation.

Modèles	Paramètres de fonction noyau	Indicateurs de performances						
		NSV	Pr	Se	Sp	F-Scr	T_tr (s)	Acc
SVM-Holdout	Linéaire ($d=1, \gamma=3.53,$ $C=879.23$)	31	97.95%	99.91%	85.80%	98.92%	771.67	98.10%
	Polynôme ($d=2, \gamma=37.17,$ $C=30.03$)	34	99.73%	99.73%	97.86%	99.73%	926.89	99.52%
	Gaussion RBF ($\sigma=91.54,$ $C=913.48$)	70	100%	99.12%	100%	99.56%	71.98	99.21%
SVM-Kfold	Linéaire ($d=1, \gamma=1,$ $C=0.007$)	29	99.90%	99.81%	99.42%	99.85%	311.76	99.75%
	Polynôme ($d=2, \gamma=12.07,$ $C=0.72$)	28	99.90%	99.71%	99.42%	99.81%	575.37	99.67%
	Gaussion RBF ($\sigma=50.60,$ $C=957.51$)	41	99.90%	99.71%	99.42%	99.81%	575.37	99.67%

Tableau. 4.6. Classification de la qualité de l'eau à l'aide du modèle SVM-SOM et des paramètres du noyau sélectionnés dans la phase de test.

Modèles	Paramètres du noyau	Indicateurs de performances					
		Pr	Se	Sp	F-Scr	T_tr (s)	Acc
SVM-Holdout	Linéaire ($d=1, \gamma=3.53, C=879.23$)	97.95%	99.91%	85.80%	98.92%	771.67	98.10%
	Polynôme ($d=2, \gamma=37.17, C=30.03$)	100%	99.79%	100%	99.90%	0.002	99.81%
	Gaussien RBF ($\sigma=91.54, C=913.48$)	99.79%	100%	98.36%	99.90%	0.003	99.81%
SVM-Kfold	Linéaire ($d=1, \gamma=1, C=0.007$)	99.65%	99.83%	92.86%	99.74%	0.002	99.50%
	Polynôme ($d=2, \gamma=12.07, C=0.72$)	99.30%	99.82%	86.67%	99.56%	0.002	99.17%
	Gaussien RBF ($\sigma=50.60, C=957.51$)	96.86%	99.64%	58.14%	98.23%	0.002	96.67%

A.4. Comparaison des performances de classification de deux modèles

Dans cette étude, la principale contribution est d'apprendre et de classer les données de qualité de l'eau à l'aide des méthodes LSTM et SVM avec une sélection de caractéristiques basée sur SOM et ACP. Comparé aux réseaux de neurones ordinaires, LSTM possède des modules de réseau de neurones répétitifs, qui peuvent traiter automatiquement les informations sémantiques clés des données d'entrée. Dans cette étude, l'optimisation de la fonction d'activation et l'optimisation du post-traitement sont effectuées sur la base du réseau LSTM d'origine, ce qui améliore considérablement la précision des résultats de classification. Le succès du cadre proposé de point de vue performance peut être vu dans les tableaux 4.4, 4.5 et 4.6. Parmi nos contributions dans ce travail est de proposer l'utilisation de SOM avec les techniques LSTM dans le domaine de la surveillance de la qualité de l'eau. Pour plus de performances de classification, nous avons utilisé deux méthodes de validation croisée à savoir : k-fold standard et Holdout, pour estimer les performances des modèles de classification utilisés et les bases de données correspondantes ainsi que le choix des paramètres des fonctions noyaux dans l'utilisation de la techniques SVM. Il apparaît sur le plan décisionnel, les deux modèles obtiennent de bons résultats avec des taux de reconnaissance supérieurs à 98% dans les phases

d'apprentissage et de test avec la sélection de caractéristiques. Le meilleur résultat d'apprentissage du modèle LSTM-SOM, est de 98,81 % de taux de reconnaissance, 99,02 % de sensibilité, 96,99 % de spécificité, 99,64 % de précision et 99,33 % de valeurs métriques de performances F1-Score sont obtenues. Le modèle SVM-SOM avec la paire appropriée ($d = 2$, $\gamma = 37,17$, $C = 30,03$), a taux de reconnaissance, de 99,81 %, une sensibilité de 99,79 %, une spécificité de 100 %, une précision de 100 % et des performances métriques F1-Score de 99,90 %. Le modèle SVM-SOM nécessite moins de temps que le temps d'apprentissage et de test par rapport au modèle LSTM-SOM. Les résultats de la classification ont clairement montré une précision et une sensibilité plus élevées pour les deux méthodes d'apprentissage automatique.

Les résultats de la classification ont montrés clairement des taux de reconnaissance plus élevés pour les deux méthodes d'apprentissage utilisées. Selon le tableau 4.7, la méthode proposée a montré des résultats moins similaires et compétitifs avec un taux de reconnaissance de 99,81 % par rapport à Mesut Togaçar et al. [24], Ahmed et al. [28] et Djerioui et al. [29] en utilisant la méthode d'apprentissage en profondeur Auto-Encoder, ELM et SVM avec base de données sur la qualité de l'eau.

Tableau. 4.7. Comparaison entre les méthodes proposées et les méthodes de classification rapportées antérieurement dans différents bases de données.

Travaux	Bases de données	Méthodes	Taux de reconnaissance
Sourav Kundu et al. [157]	EEG signal	SAE-ESVM	95.5%
Indu Saini et al. [158]	MIT-BIH Arrhythmia database.	KNN algorithm	99.81
Shao Haidong et al. [159]	Fault diagnosis	Enhancement Auto-Encoder	87.8%
Ahmed et al. [160]	Water quality database	MLP	85%
Djerioui et al. [161]	Water quality database	SVM and ELM	99,3%
Mesut Togaçar et al. [156]	Waste water quality database	Auto-Encoder	99.95
Notre travail [137]	Water quality database	SVM	99,81%
		LSTM	98,70

Cette évaluation est en accord avec les résultats publiés par plusieurs travaux. Ils ont signalé que les modèles LSTM ou SVM ont une précision de classification élevée pour les données sur la qualité de l'eau, car ils utilisent les avantages de ces méthodes qui combinent

les lacunes des techniques conventionnelles avec différentes méthodes, bases de données et champs d'applications lors de l'évaluation des performances globales obtenues. Dans ce travail, nous constatons que des résultats meilleurs ou au moins similaires et compétitifs sont obtenus par rapport aux résultats d'approches similaires. De plus, notre approche réduit considérablement les temps d'apprentissage et de test en utilisant la sélection des caractéristiques basée sur SOM et ACP. L'impact de ce résultat est significatif sur le plan technique (temps d'apprentissage réduit) qu'économique (réduction du nombre de capteurs) et peut améliorer évidemment les performances de notre système de surveillance.

Les résultats obtenus mettent l'accent sur l'explication des raisons théoriques et pratiques de la technique LSTM pour ce type d'application. De plus, les modèles LSTM peuvent prédire les valeurs séquentielles et volumineuses pour fournir une plus grande précision avec une meilleure prise de décision. Dans notre cas, les données que nous avons utilisées pour l'évaluation de la qualité de l'eau sont présentées avec une saisonnalité différente, ce qui permet à LSTM de bien les gérer par rapport aux autres modèles d'apprentissage automatique conventionnels.

4.4.3. Approche de diagnostic par régression : Détection des anomalies, Validation et reconstruction des données manquantes

La production d'une eau potable de qualité élevée et uniforme nécessite la mesure de la qualité des différents paramètres relatifs à la qualité de l'eau en entrée. Les capteurs défectueux peuvent entraîner une mauvaise interprétation de la qualité de l'eau ce qui mène à une mauvaise décision comme la dose optimale du coagulant à injecter ce qui mène à une dégradation de la qualité de l'eau potable. Une deuxième étude concernant l'auto-validation et l'autocorrection des capteurs dans une station de production de l'eau potable lorsqu'il y a une détection de défaut au niveau des capteurs, l'identification du capteur défectueux et la reconstruction d'information de ce capteur.

Dans cette section, nous avons évalué l'approche proposée sur plusieurs paramètres physico-chimiques utilisés pour la décision sur la qualité de l'eau. Dans cette application, deux modèles non supervisés de classification avancés, y compris la classification ascendante hiérarchique (CAH) et les cartes auto-organisées (SOM), sont utilisés pour l'évaluation de la qualité de l'eau. Les bases de données utilisées de la station du barrage du Cheliff à Mostaganem et du Tilesdit à Bouira qui sont constituées de même quatre variables physico-chimiques : température (T°), pH, conductivité électrique (EC) et

turbidité (TU) réduites par l'étape de sélection des caractéristiques basées sur le SOM et ACP en entrée des modèles de détection d'anomalies proposés.

La figure 4.9 et 4.10 illustre la variation de toutes les variables au cours d'une période de collecte de données de la station du Tilesdit à Bouira (1800 échantillons) et du barrage du Cheliff à Mostaganem (284 échantillons) respectivement. Des analyses préliminaires ont été menées pour évaluer le comportement non linéaire des données tout au long de l'intervalle d'étude.

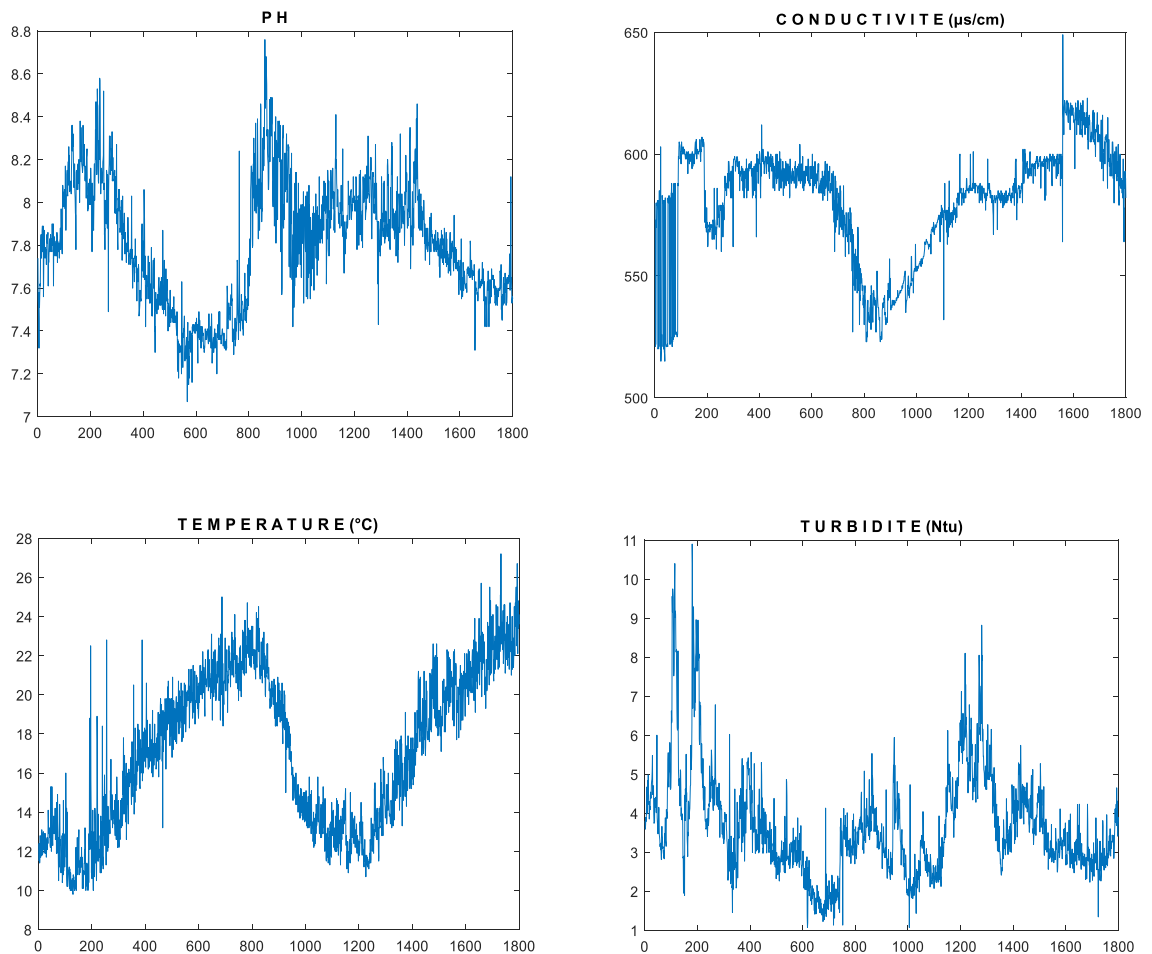


Fig. 4.9. Caractéristiques de l'eau brute – Barrage Tilesdit.

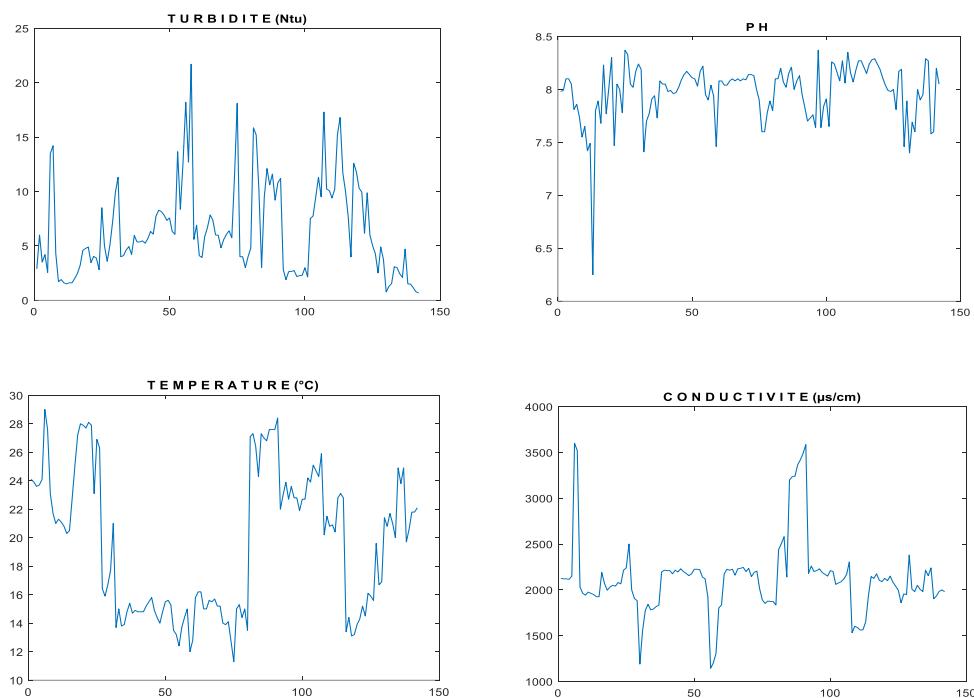


Fig. 4.10. Caractéristiques de l'eau brute (Cheliff)

A. Détection des anomalies

Les algorithmes CAH et SOM ont été appliqués aux deux jeux de données précédemment utilisées (Tiledit et Cheliff). Les mesures présentées sur la Fig. 4.11 sont utilisées pour effectuer la formation SOM (training), avec 4 variables pour obtenir une sortie visuelle, La classification SOM peut également être fournie sous un format numérique des 4 capteurs en 2 groupes (Tableau 4.8).

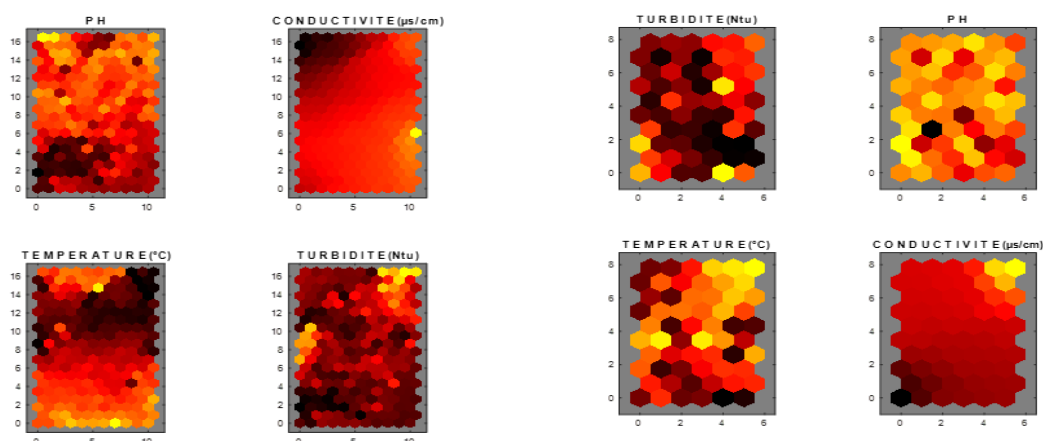


Fig. 4.11, (a). Plans composants du SOM pour un fonctionnement normal (Tiledit).

Fig. 4.11, (b). Plans composants du SOM pour un fonctionnement normal (Cheliff).

La figure 4.12 (a et b) montre une présentation graphique des résultats obtenus par la classification ascendante hiérarchique (CAH) appelée dendrogramme. La comparaison de l'approche CAH hiérarchique et de l'approche SOM donne exactement les mêmes résultats [138]. CAH donne une division pour deux groupes de variables liées, tandis que SFOM donne définitivement deux groupes (les deux groupes de deux méthodes sont présentés dans les figure 4.11 a et b, figure 4.12 a et b et le tableau 4.8). Le regroupement par SOM ressemble à ceux obtenus par CAH [138]. Le groupe II contient (Turbidité, pH, Température), le premier groupe contient la Conductivité. En général, la visualisation SOM est en bon accord avec les résultats obtenus par CAH.




Fig. 4.12, (a). Dendrogramme CAH, fonctionnement normal (4 capteurs) – Barrage Tilesdit.




Fig. 4.12, (b). Dendrogramme CAH : fonctionnement normal (4 capteurs) – Barrage Cheliff.

Tableau. 4.8. Classification décision pour un fonctionnement normal SOM et Méthode CAH.

Bases de données	pH	Conductivité	Température	Turbidité
Tilesdit	2	1	2	2
Cheliff	2	1	2	2

Cette présentation illustrée aux figures 4.11 (a et b) et 4.12 (a et b) et le tableau 4.8 est considérée comme une description de référence qui nous permet de comparer à d'autres mesures que nous voulons distinguer si elles sont normales ou anormales. Chaque dissemblable à cette présentation est considéré comme anormal. Alors, pour déterminer si des informations erronées sont émises par les capteurs, des tests d'hypothèse doivent être

effectués par la construction des évaluations statistiques de test, qui jouent un rôle crucial dans la détection d'anomalies dans la surveillance du processus. Dans l'étape suivante, on va générer un défaut au niveau d'un capteur quelconque et nous remarquons les changements dans les deux présentations.

- Dans ce premier exemple, un défaut est introduit le 500^{ème} et le 50^{ème} jour au niveau du capteur de pH (en modifions sa valeur dans la base de données de 7.42 à 70.42 et de 7.57 à 75.7 respectivement) comme montre les deux figures 4.13-(a) et 4.14-(a). La détection du défaut apparaît sur les deux présentations CAH et SOM (la figure 4.15-(a et b) et la figure 4.17-(a et b)). Le changement de classification de capteur de pH sur le dendrogramme (figure 4.15-(a, b)) par rapport au dendrogramme de référence montre un diagnostic d'un défaut, aussi les plans des composants de la carte SOM présentés sur la figure 4.17-(a, b) qui montre un modèle différent de celle du fonctionnement normal (le plan du capteur de pH n'est pas similaire au plan normal); ce changement confirme qu'un défaut est détecté au niveau du capteur de pH.

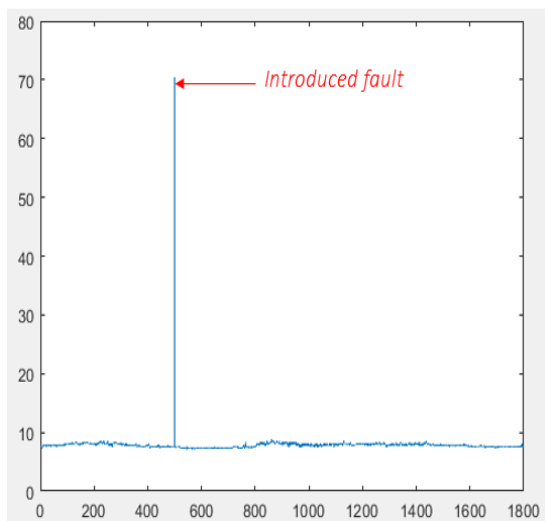


Fig. 4.13, (a). Mesure du pH avec défaut artificiel- Barrage Tilesdit.




Fig. 4.13, (b). Mesure de Conductivité avec défaut artificiel- Barrage Tilesdit




Fig. 4.14, (a). Mesure du pH avec défaut artificiel- Barrage Cheliff.




Fig. 4.14, (b). Mesure de conductivité avec défaut artificiel - Barrage Cheliff.




Fig. 4.15, (a). détection de défaut du capteur pH-Barrage Tilesdit.




Fig. 4.16, (a). détection de défaut du capteur Conductivité-Barrage Tilesdit.




Fig. 4.15, (b). détection de défaut du capteur pH – Barrage Cheliff




Fig. 4.16, (b). détection de défaut du capteur Conductivité-Barrage Cheliff.




Fig. 4.17, (a). Plans des composants du SOM montrant le défaut du capteur pH-Barrage Tilesdit.




Fig. 4.17, (b). Plans des composants du SOM montrant le défaut du capteur pH - Barrage Cheliff.

- Le même travail est répété sur le capteur de conductivité, un défaut est généré au 800^{ème} et 80^{ème} jour (en modifions sa valeur dans la base de données de 530 à 5.3 et de 1834 à 18.34 respectivement) comme montre les deux figures 4.13-(b) et 4.14-(b). Les présentations graphique de CAH et les cartes SFOM sont illustrées dans les deux figures 4.16-(a, b) et 4.18-(a, b) respectivement montre des modèles différents des modèles de références, ce qui signifie qu'un défaut est arrivé au capteur de conductivité.




Fig. 4.18, (a). Plans des composants du SOM indiquant le défaut du capteur de conductivité - Barrage Tilesdit.




Fig. 4.18, (b) Plans des composants du SOM indiquant le défaut du capteur de conductivité - Barrage Cheliff.

- Le cas d'une simulation de deux défauts en même temps : on va générer deux défauts en même temps sur deux capteurs différents (capteur pH et conductivité) au 600^{ème} et 60^{ème} jour. Le changement de la présentation SFOM et de la présentation sur le dendrogramme CAH des deux capteurs affirme qu'un dysfonctionnement s'est produit au niveau des deux capteurs 1 et 2 (Figure. 4.19, (a et b)) et (Figure. 4.20, (a et b)).




Fig. 4.19, (a). Plans des composants du SFOM montrant le défaut des capteurs de conductivité et de pH- Barrage Tilesdit.




Fig. 4.19, (b). Plans des composants du SFOM montrant le défaut des capteurs de conductivité et de pH-Barrage Cheliff.




Fig. 4.20, (a). Détection de défaut du capteur de conductivité et de pH-Barrage Tiledit.




Fig. 4.20, (b). Détection de défaut des capteurs de conductivité et de pH-Barrage Cheliff.

B. Validation et reconstruction des données manquantes

Dans la section précédente, nous avons montré l'application de la technique SOM à la détection de données aberrantes. Nous allons maintenant présenter comment utiliser ce modèle pour traiter les données invalides ou manquantes. Cette approche peut représenter les connaissances obtenues à partir des données sous forme de modèles (prototypes) ou de vecteurs de référence. Cette méthode propose d'estimer toutes les valeurs manquantes d'un vecteur dans un même système, quel que soit le nombre de variables disponibles. Néanmoins, il est évident que l'exactitude de la reconstruction dépendra du nombre de variables disponibles par rapport au nombre de variables manquantes. Pour évaluer les performances de la méthode de validation et de reconstruction des données manquantes, des tests de simulation ont été réalisés et des résultats ont été comparés aux résultats réels de références de la base de Tiledit. Deux défauts ont été artificiellement introduits entre le 650^{ème} et le 670^{ème} jour au niveau du capteur qui mesure le pH (figure. 4.21-a), et l'autre entre le 500^{ème} et le 510^{ème} jour au niveau du capteur de conductivité (figure. 4.21-b). La Figure 4.22-(a et b) montre la reconstruction des données manquantes pour le pH défectueuse. Après avoir visualisé quel descripteur doit être précisément déclaré défectueux (dans notre cas le capteur de pH et le capteur de conductivité, ces échantillons anormaux sont ensuite retirés pour calculer un nouveau prototype récupéré avec uniquement des échantillons normaux. La figure 4.23-(a et b) montre les valeurs de reconstruction des données manquantes pour la conductivité défectueuse. La procédure

SOM permet le rejet des échantillons atypiques et met donc en œuvre une sorte de «détection de nouveauté». Cependant, ce type de rejet peut provenir de sources d'acquisition de données peu fiables, de capteurs défectueux, d'erreurs de collecte de données ou simplement d'un manque d'exhaustivité des données. Il s'agit d'une approche conservatrice des changements de données. Nous notons que l'approche adoptée dans ce travail basé sur SOM et CAH a presque reconnues les échantillons défectueux. De plus, l'approche SOM permet d'estimer les variations de ces échantillons. La fiabilité et la robustesse de cette approche sont justifiées par le processus de validation-reconstruction des mesures erronées. La comparaison entre les valeurs réelles et les valeurs estimées convient que cette méthode à adopter donne des résultats approximatifs, mais pas exacts.




Fig. 4.21, (a). Mesure du pH avec un défaut artificiel- Barrage Tilesdit.




Fig. 4.21, (b). Mesure de la conductivité avec un défaut artificiel- Barrage Tilesdit.





Fig. 4.22, (a et b). Reconstruction du pH défectueuse-BarrageTilesdit




Fig. 4.23, (a et b). Reconstruction de conductivité défectueuse-Barrage Tilesdit

- Pour évaluer les performances de la méthode de validation et de reconstruction des données manquantes, des tests de simulation ont été réalisés et des résultats ont été comparés aux résultats réels de références de la base de Cheliff. Un défaut est artificiellement introduit entre le 65ème et le 67ème jour au niveau du capteur qui mesure le pH (figure. 4.24-a), et un autre défaut entre le 50ème jour et le 56ème jour au niveau du capteur de conductivité (figure. 4.24- b). La Figure 4.25- (a et b) montre la reconstruction des données manquantes pour cette méthode pour le pH défectueuse. La figure 4.26 - (a et b) montre les valeurs de reconstruction des données manquantes pour la conductivité défectueuse. Après avoir visualisé quel descripteur doit être précisément déclaré défectueux (dans notre cas le capteur de pH et le capteur de conductivité), ces échantillons anormaux sont ensuite retirés pour calculer un nouveau prototype récupéré avec uniquement des échantillons normaux. Les tableaux 4.11 et 4.12 résument et illustrent les différentes données erronées reconnues à l'aide de l'approche SOM et CAH. Nous notons que l'approche adoptée dans ce travail basé sur SOM et CAH a pu presque reconnu les échantillons défectueux. De plus, l'approche SFOM permet d'estimer les variations de ces échantillons et de valider et reconstruire les données manquantes. La fiabilité et la robustesse de cette approche sont justifiées par le processus de validation-reconstruction des mesures erronées. La comparaison entre les valeurs réelles et les valeurs estimées convient que cette méthode à adopter, donne des résultats approximatifs, mais pas exacts.




Fig. 4.24, (a). Mesure du pH avec un défaut artificiel- Barrage Cheliff




Fig. 4.24, (b). Mesure de conductivité avec un défaut artificiel- Barrage Cheliff





Fig. 4.25. (a et b). Reconstruction du pH défectueuse-Barrage Cheliff





Fig. 4.26. (a et b). Reconstruction de conductivité défectueuse-Barrage Cheliff

Tableau. 4.9. Valeurs du pH réelles, prévues et aberrantes du barrage de Tilesdit.

Jours	650 ^{ème} jours	651 ^{ème} jours	652 ^{ème} jours	653 ^{ème} jours	654 ^{ème} jours	655 ^{ème} jours	656 ^{ème} jours	657 ^{ème} jours	658 ^{ème} jours	659 ^{ème} jours	660 ^{ème} jours	661 ^{ème} jours	662 ^{ème} jours	663 ^{ème} jours	664 ^{ème} jours	665 ^{ème} jours	666 ^{ème} jours	667 ^{ème} jours	668 ^{ème} jours	669 ^{ème} jours	670 ^{ème} jours
Valeur réel	7.37	7.37	7.38	7.35	7.4	7.41	7.42	7.32	7.43	7.48	7.41	7.25	7.31	7.33	7.34	7.36	7.37	7.3	7.34	7.37	7.4
Valeur estimé	7.81	7.80	7.76	7.80	7.77	7.75	7.80	7.76	7.80	7.78	7.81	7.80	7.79	7.75	7.78	7.76	7.72	7.74	7.79	7.79	7.78
Valeur fausse	70.37	70.37	70.38	70.35	70.4	70.41	70.42	70.32	70.43	70.48	70.41	70.25	70.31	70.33	70.34	70.36	70.37	70.3	70.34	70.37	70.40

Tableau. 4.10. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Tilesdit.

Jours	500 ^{ème} jours	501 ^{ème} jours	502 ^{ème} jours	503 ^{ème} jours	504 ^{ème} jours	505 ^{ème} jours	506 ^{ème} jours	507 ^{ème} jours	508 ^{ème} jours	509 ^{ème} jours	510 ^{ème} jours
Valeur réel	597	587	587	595	596	594	589	590	596	596	594
Valeur estimé	573.92	580.60	576.05	582.42	576.68	577.95	580.06	578.95	578.93	574.90	574.44
Valeur fausse	5.97	5.87	5.87	5.95	5.96	5.94	5.89	5.90	5.96	5.96	5.94

Tableau. 4.11. Valeurs du pH réelles, prévues et aberrantes du barrage de Cheliff.

Jours	65 ^{ème} jours	66 ^{ème} jours	67 ^{ème} jours	68 ^{ème} jours	69 ^{ème} jours	70 ^{ème} jours	71 ^{ème} jours	72 ^{ème} jours	73 ^{ème} jours
Valeur réel	8.10	8.08	8.10	8.08	8.10	8.09	8.14	8.14	8.13
Valeur estimé	7.7446	7.3009	7.4956	7.5173	7.6062	7.6591	7.6187	7.6781	7.5087
Valeur fausse	80.10	80.08	80.10	80.08	80.10	80.09	80.14	80.14	80.13

Tableau. 4.12. Valeurs de conductivité réelles, prévues et aberrantes du barrage de Cheliff.

Jours	50 ^{ème} jours	51 ^{ème} jours	52 ^{ème} jours	53 ^{ème} jours	54 ^{ème} jours	55 ^{ème} jours	56 ^{ème} jours
Valeur réel	2225	2225	2220	2140	2120	1920	1144
Valeur estimé	2053.3	2037.1	2067.7	2041.9	2065.5	2037.6	2090.9
Valeur fausse	22.25	22.25	22.2	21.4	21.2	19.2	11.44

Tableau. 4.13. Mesures de performance des résultats de la reconstruction des données pour les deux barrages.

Paramètres	RMSE pH	RMSE Conductivité
Tilesdit	0.0448	1.2481
Cheliff	0.1383	84.3795

Les résultats que nous avons obtenus par cette étude sont similaires et compétitifs et en combinaison avec ceux obtenus par B. Lamrini et al. [162] et Y. Zhang et al. [163]. Les deux techniques SOM et CAH montrent le point clé du processus de détection des anomalies, Validation et reconstruction des données manquantes.

4.4.4. Approche de surveillance et de contrôle : Prédiction de la dose du coagulant, l'indice de qualité de l'eau et capteurs logiciels

A.1. Approche de contrôle par la prédiction de la dose du coagulant - Capteurs logiciels

Dans cette section, nous avons évalué l'approche proposée sur plusieurs paramètres physico-chimiques utilisés pour la modélisation des capteurs logiciels. La base de données utilisée est constituée des quatre variables physicochimiques : température (T°), pH, conductivité électrique (EC) et turbidité (TU) réduites par l'étape de sélection des caractéristiques basées sur la SOM et l'ACP en entrée du modèle de capteur logiciel proposé (Figure. 4.10) et après avoir utilisé aussi les méthodes SOM et CAH pour la détection des anomalies et la validation et reconstruction des données manquantes. La prédiction du dosage optimal de coagulant à partir des caractéristiques de l'eau validées et reconstruites dans le cas où des défauts sont détectés, est un problème de régression non linéaire qui peut être résolu à l'aide de méthodes d'apprentissage statistiques. La technique SVM appliquée à la régression (SVR) a été utilisée dans ce cas-là pour prédire le dosage optimal de coagulant. Les mesures optimales de dosage de coagulant déterminent les performances des capteurs logiciels de régression. Cela dépend également de l'intervalle d'échantillonnage utilisé dans la génération des données d'entraînement et de test.

Dans la formulation SVR, C et ε sont deux paramètres au choix spécifiés par l'utilisateur ; tandis que C représente le compromis entre la complexité du modèle et l'erreur d'approximation, ε signifie la largeur de la zone ε -insensible utilisée pour ajuster les données d'apprentissage. Ces deux paramètres indiqués ainsi que la forme spécifique de la fonction noyau contrôlent la précision et la performance de généralisation de l'estimation de régression.

Pour évaluer la méthode utilisée, une validation croisée de 10-Fold a été effectuée dans les phases d'apprentissage et de test de la base de données Cheliff. Le processus de validation croisée peut arrêter le problème de sur-ajustement qui est très important dans la sélection aléatoire de sous-échantillons utilisée pour tester et apprendre des ensembles de données et des paramètres. Nous pouvons développer des modèles de régression avec des performances et une précision élevées grâce à l'utilisation de la validation croisée. Nous utilisons une validation croisée de 10-Fold pour rechercher également le paramètre de noyau approprié, à savoir la largeur du noyau RBF (σ), le coefficient de pénalisation (C) et

le paramètre de fonction de perte (ϵ). Il a été constaté que RBF en tant que fonctions du noyau a les meilleures performances parmi les fonctions testées. Pour obtenir un modèle SVR optimal, il est nécessaire d'examiner les effets de la fonction du noyau et de ses paramètres. Les valeurs optimales des paramètres spécifiques au SVR qui ont minimisé sont : le RMSE est répertoriées dans le tableau 4.14. Toutes les paires de (C, σ) pour le noyau RBF sont testés et celle donne la meilleure précision de validation croisée est sélectionnée. Les meilleures valeurs optimales des paramètres de la fonction RBF du modèle SVR sont $(C = 1000$ et $\sigma=10)$.

L'étape d'apprentissage utilisant les hyper-paramètres indiqués ci-dessus, les Figure 4.27 et Figure 4.28 montrent l'une des comparaisons de validation croisée de 10-Fold entre la valeur réelle mesurée de la dose optimale de coagulant et les valeurs prédites de l'ensemble de données d'apprentissage et de test, respectivement [139].




Fig. 4.27. Comparaison entre les valeurs réelles mesurées et prédites de dose optimale de coagulant de l'ensemble de données d'apprentissage.

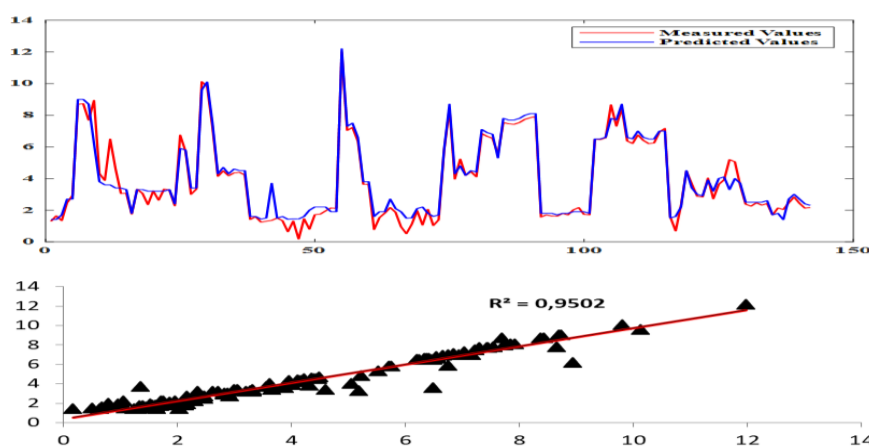


Fig. 4.28. Comparaison entre les valeurs réelles mesurées et prédites de dose optimale de coagulant de l'ensemble de données de test.

On peut facilement remarquer que les vecteurs d'entraînement ($R^2 = 0,9979$) et les vecteurs de test ($R^2 = 0,9502$) sont distribués à proximité de la ligne parfaite, ce qui signifie que le dosage optimal de coagulant prédit avec la méthode SVR proposée a une grande précision pour les deux bases d'apprentissage et de test de l'ensembles de données.

Les deux indices évalués (RMSE : Racine care de l'erreur quadratique ; R^2 : Coefficient de détermination) de tous les échantillons d'apprentissage et de test sont présentés dans le tableau 4.14 [139].

Tableau. 4.14. Mesures de performance du modèle SVR de capteur logiciel de la dose optimal de coagulant.

Paramètres	Apprentissage	Test
RMSE	0.11	0.58
R^2	0.9979	0.9502
Temps de test	38.81 <i>sec</i>	0.03 <i>ms</i>

D'après le tableau 4.14, les RMSE des ensembles de données d'apprentissage sont relativement faibles et de niveau d'erreur faible avec R^2 à un niveau élevé, ce qui signifie que la valeur de dosage de coagulant optimale prédite par le modèle basé sur SFOM/ACP-SVR est de haute précision et stabilité. Par rapport aux résultats de prédiction des ensembles d'apprentissage, les indices évalués des ensembles de test ont légèrement échangé avec quelques fluctuations, mais sont toujours restés dans une fourchette raisonnable. Bien que la performance prédictive des échantillons d'apprentissage soit meilleure que celle des échantillons de test, les indices évalués correspondant à toutes les validations croisées de 10-Fold sont raisonnables car les échantillons de test sont tous nouveaux pour le modèle formé par les ensembles d'apprentissage. Ces résultats sont équivalents aux résultats obtenus par Djerioui et al. [161], Fan et al. [164] et Jain et al. [165] dans différentes bases de données et applications qui ont fonctionné sur les échantillons d'entraînement et de test avec validation croisée utilisant des modèles de capteurs logiciels SVR. Dans tous les cas, cette solution n'est pas définitive, un système de réapprentissage devrait probablement être mené périodiquement afin que les situations qui pourraient survenir soient prises en compte et ajustées en permanence pour faire évoluer la qualité de l'eau.

A.2. Approche de surveillance : Indice de qualité - Capteurs logiciels

L'évaluation de la qualité de l'eau peut être utilisée pour évaluer les propriétés de l'eau en référence à la qualité naturelle et aux effets sur la santé humaine. Il peut être évalué en mesurant un large éventail de variables pour représenter le niveau de pollution de l'eau. Par conséquent, une technique mathématique robuste est nécessaire pour combiner la caractérisation physico-chimique de l'eau en une seule variable qui décrit la qualité de l'eau. Compte tenu de cela, un indice de qualité de l'eau (IQE) a été développé sous la forme d'un nombre unique qui utilise un ensemble de variables physico-chimiques de l'eau pour expliquer la qualité de l'eau à un certain endroit et à un certain moment. L'IQE est un nombre sans unité qui reflète l'état de la qualité de l'eau. Le concept d'IQE est basé sur la comparaison du paramètre de qualité de l'eau avec les normes réglementaires respectives.

Il existe plusieurs équations pour l'IQE dans différents pays tels que les États-Unis, Canada et la Malaisie, qui sont développées sur la base des normes de la US National Sanitation Foundation. Dans notre étude, douze (12) paramètres ont été choisis comme principales variables de qualité de l'eau pour développer IQE pour les eaux de surface de la zone d'étude de barrage de Tilesdit de Bouira – Algérie dans l'année 2018 (tableau 4.15). Ces variables doivent être converties en paramètres non dimensionnels par des fonctions de sous-indice.

La méthode conventionnelle nécessite des transformations de longue durée pour calculer les sous-indices. De plus, les sous-indices nécessitent l'inclusion de différentes équations, qui nécessitent beaucoup d'efforts et de temps pour estimer l'IQE final. Par conséquent, l'estimation d'un tel IQE est lourde et peut conduire à des erreurs occasionnelles.

Tableau. 4.15. Base de données sur les normes d'eau brute 2009 et 2011 – Barrage Tilesdit

Années	Paramètres de pollution (mg/l)							
	NH ₄ ⁺ (mg/l)	NO ⁻² (mg/l)	Ca ²⁺ (mg/l)	Cl ⁻ (mg/l)	HCO ₃ ⁻ (mg/l)	TH (CaCO ₃) (mg/l)	PEH(CaCO ₃) (mg/l)	TAC (mg/l)
2009	0,08	0,07	52,37	59,17	219,45	224,83	46,98	179,01
2011	0,12	0,08	36,19	52,12	206,95	195,05	21,69	169,00
Années	Paramètres physico-chimiques							
	Conductivité à 25°C (ms/cm)		Température (°C)		Turbidité (NTU)		pH	
2009	580,08		16,30		3,68		7,60	
2011	543,12		15,30		2,50		6,98	

• Calcul de l'Indice de qualité de l'eau (IQE)

Le calcul de l'IQE est une technique de classification de la qualité de l'eau qui repose sur la comparaison des paramètres de qualité de l'eau avec les normes internationales ou nationales dans le cadre de cette étude. Ces variables doivent être converties en variables non dimensionnelles à l'aide des fonctions de sous-indice (SI). L'IQE résume de grandes quantités de données sur la qualité de l'eau en termes simples (Excellente, Bonne, Mauvaise, Très mauvaise, etc.). Dans cette étude l'indice IQE est appliqué pour estimer l'influence des facteurs naturels et anthropiques sur la base de plusieurs paramètres clés du chimisme des eaux de surface de barrage Tilesdit. Cet indice est calculé en suivant la méthode de l'indice arithmétique pondéré. Dans cette approche, une valeur numérique appelée poids relatif (W_i), spécifique à chaque paramètre physico-chimique, est calculée selon la formule suivante :

$$W_i = \frac{k}{s_i} \quad (4.5)$$

Où :

W_i : le poids de chaque paramètre selon son importance relative dans la qualité des eaux de boisson,

K : constante de proportionnalité et peut également être calculée à l'aide de l'équation suivante :

$$K = \frac{1}{\sum_{i=1}^n \left(\frac{1}{s_i}\right)} \quad (4.6)$$

n : nombre de paramètres,

S_i : valeur maximale de la norme standard algérienne des eaux de surface de chaque paramètre en mg/l sauf pour le pH, T° et la conductivité électrique.

Ensuite, une échelle d'évaluation de la qualité (Q_i) est calculée pour chaque paramètre en divisant la concentration par la norme du paramètre et en multipliant l'ensemble par 100 comme dans la formule suivante :

$$Q_i = \left(\frac{C_i}{S_i}\right) * 100 \quad (4.7)$$

Q_i : échelle d'évaluation de la qualité de chaque paramètre.

C_i : la concentration de chaque paramètre en mg/l .

Finalement l'indice global de la qualité de l'eau (IQE) est calculé par l'équation suivante :

$$IQE = \frac{\sum_{i=1}^n Q_i * W_i}{\sum_{i=1}^n W_i} \quad (4.8)$$

Cinq classes de qualité peuvent être identifiées selon les valeurs de l'indice de qualité de l'eau IQE selon les normes et les recommandations de l'Organisation mondiale de la santé (OMS) relatives à la qualité de l'eau (tableau. 4.16).

Tableau. 4.16. Classification et usage possible de l'eau selon l'IQE [166, 167, 168]

Classe d'IQE	Type d'eau	Usage possible
0 - 25	Excellente qualité	Eau potable, irrigation et industrie
>25 - 50	Bonne qualité	Eau potable, Irrigation et industrie
>50 - 75	Mauvaise qualité	Irrigation et industrie
>75 - 100	Très mauvaise qualité	Irrigation
> 100	Eau non potable	Traitement approprié requis avant utilisation

Le poids relatif (W_i) de chaque paramètre physico-chimique et la constante de proportionnalité K sont calculés en premier lieu en utilisant les valeurs maximales de la norme standard algérienne des eaux de surface des paramètres physicochimiques étudiés. Le calcul de l'indice de qualité de l'eau (IQE) de ces paramètres physico-chimiques sont illustrées dans les tableaux 4.17 et 4.18.

Tableau. 4.17. Valeur des paramètres physiques et chimiques et normes algériennes de qualité des eaux de surface année 2018.

Paramètres	S_i valeur maximale standard, Algérie	$1/S_i$	W_i	Q_i (Aout-11)	Q_i (Sept-11)	Q_i (Oct-11)	Q_i (Nov-11)	Q_i (Dec-11)
pH	7	0.142	0.019	106.231	106.603	110.141	112.539	112.765
Conductivité à 25 °C ms/cm	2700	0.000	0.000	21.666	24.021	20.907	20.424	21.025
Température °C	25	0.040	0.005	81.375	72.323	75.158	67.981	58.857
Turbidité (NTU)	5	0.200	0.026	45.718	34.624	61.730	54.244	44.354
Ammonium (mg/l)	0.5	2.000	0.268	49.8	43.34	18.537	15.622	37.93
NO ⁻² (mg/l)	0.2	5.000	0.67	8.225	77.372	0	0	7.862
Ca ²⁺ (mg/l)	200	0.005	0.000	24	21.2	17.8	16.38	21
Cl ⁻ (mg/l)	500	0.002	0.000	10.65	12.07	12.815	12.581	11.786
HCO (mg/l)	50	0.020	0.002	488	479.866	366	361.264	376.38
TH (mg/l)	200	0.005	0.000	108	109.666	98.25	74.8	90.5
Dureté permanente (mg/l)	200	0.005	0.000	8	11.333	10.025	2.87	10.856
Titre alcalin complet (mg/l)	500	0.002	0.000	40	40.333	30	29.612	30.85
	$\sum S_i$	7.42						
	$\frac{1}{K = \sum (1/S_i)}$	0.13						

Tableau. 4. 18. Valeurs de l'indice IQE et classe de qualité des eaux de surface pour le barrage de Tilesdit dans l'année 2018

Mois	IQE	Classe de qualité de l'eau
Janv-18	47.66	Bonne qualité
Fevr-18	36.15	Bonne qualité
Mars-18	38.94	Bonne qualité
Avr-18	43.92	Bonne qualité
Mai-18	36.64	Bonne qualité
Juin-18	100.26	Eau non potable
Juil-18	64.48	Mauvaise qualité
Aout-18	23.68	Excellente qualité
Sept-18	68.38	Mauvaise qualité
Oct-18	9.87	Excellente qualité
Nov-18	8.89	Excellente qualité
Dec-18	19.97	Excellente qualité

Quatre classes de qualité dans notre cas peuvent être identifiées selon les valeurs de l'indice de qualité de l'eau IQE obtenus (Excellente, bonne, mauvaise et non potable) sont identifiées lors des mois Juin, Juillet et Septembre. L'indice de qualité de l'eau IQE montre qu'au passage automne -hiver -printemps Octobre - Mai, sont de bonne à excellente qualité ($8.89 < IQE \leq 47.66$). Les mois de Juin montre une qualité de l'eau non potable ($IQE > 100$). Les mois de Juillet et Septembre montrent une qualité mauvaise ($IQE > 50 - 75$).

• Prédiction d l'indice IQE par RNA

Nous avons utilisé un RNA de type PMC (Perceptron multicouche) conventionnel avec une couche cachée d'unités sigmoïdes. Pour former les MLP, un ensemble de formation de 1800 vecteurs de mesure complets a été construit en supprimant les données erronées. Un total de 1260 échantillons (environ 70%) a été utilisé pour la phase d'apprentissage et le reste étant utilisé comme ensemble de test. L'apprentissage du modèle comprenait : la recherche de la meilleure structure adoptée et l'estimation de la précision de la prédiction.

Dans cette partie de travail on s'intéresse à la conception d'un modèle de prédiction de l'indice de qualité de l'eau (IQE) (figure 4.29) permettant de fournir une information sur la valeur unique de l'indice IQE à partir d'autres paramètres physico-chimiques. L'intérêt aussi bien économique que technique, permet d'assurer un fonctionnement permanent et

stable de l'analyse et la surveillance de l'état de l'eau. Le problème posé est vu comme un problème de régression, où la sortie du modèle est l'indice de qualité de l'eau estimée.

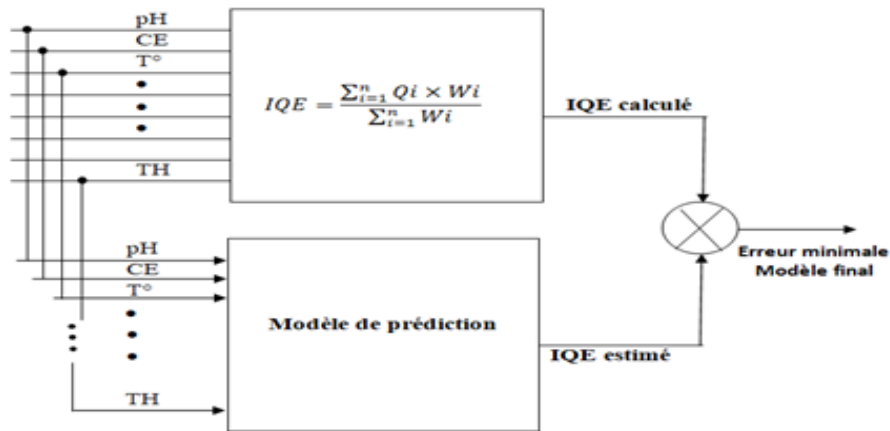


Fig. 4.29. Modèle de prédiction de l'indice IQE par RNA.

Le but recherché quant à l'application de la méthode choisie, se limite à une simulation appliquée sur des données réelles utilisées auparavant. L'indice de qualité de l'eau (IQE) est déduit d'une combinaison non-linéaire des 12 paramètres précédemment annoncés (tableau 4.17). Le modèle RNA possède l'avantage de pouvoir intrinsèquement décrire des relations non linéaires entre les variables d'entrée et celles de sortie d'un processus donné. Il reste alors à identifier les paramètres du modèle, une étape connue sous le terme d'apprentissage. En effet, les données de l'historique sont d'abord séparées en deux groupes : un groupe de données constituant la base d'apprentissage, et un groupe de données de généralisation (test) non utilisées lors de l'apprentissage, mais servant à « tester » le modèle lors de la phase de reconnaissance une fois celui-ci établi.

Les résultats d'apprentissage et de test obtenus avec le modèle RNA sont présentés dans les figures 4.30 et 4.31 respectivement [139, 166, 167].




Fig. 4.30. Résultats d'apprentissage de l'IQE par le modèle RNA.




Fig. 4.31. Résultats de test de l'IQE par le modèle RNA.

La technique RNA a été utilisée pour développer l'IQE dans la zone d'étude à surface libre. Présentée pour un problème de prédiction, la technique a fourni de très bons résultats de simulation. La base de données réelle provenant de la station Tilesdit de Bouira est appliquée à la technique en question sur une période de 12 mois, et un vaste ensemble de données a été collecté pour 12 variables de qualité de l'eau, a montré l'efficacité de cette approche. L'indice de la qualité globale de l'eau IQE était un outil très utile pour prendre la bonne décision et évaluer de façon comparative la qualité de l'eau dans le temps et dans l'espace.

D'après ces résultats, on trouve que le coefficient de corrélation ($R^2=0.99$) entre les valeurs estimées et réelles de l'IQE est tout à fait satisfaisant dans la phase de test. Une valeur élevée du coefficient de corrélation est indiqué. La précision de l'estimation est confirmée par l'absence de valeurs aberrantes. Une bonne aptitude en phase de généralisation justifiée par de forts taux de reconnaissance, a été obtenue pour le modèle RNA [139, 166, 167]. Il est clairement démontré que les sorties calculées et estimées dans les deux phases sont significativement plus proches. C'est confirmer ce fait par la comparaison visuelle donnée dans ces figures où il y a une superposition presque totale des données de sortie simulées et réelles. Cette méthode RNA était capable de prédire avec succès l'IQE avec une grande précision. Cette recherche met en évidence que les méthodes à base d'apprentissage statistique peuvent être utilisées comme des méthodes puissantes et très fiables pour estimer la qualité de l'eau. Ces techniques sont fortement recommandées pour être utilisées pour des évaluations précises, rapides et rentables de la qualité de l'eau pour tout système de production d'eau.

Conclusion

Le dernier chapitre fait l'objet d'une étude de simulation qui traite de l'application des techniques évoquées dans les chapitres précédents dans le domaine du contrôle, la surveillance et le diagnostic de l'eau propre. Les deux bases de données réelle provenant de la station Tilesdit de Bouira et la station de Sidi Lahdjel (MAO lot 1) de barrage de Cheliff de Mostaganem et appliquées aux techniques en question, ont montrées l'efficacité de cette approche.

Cette étude permet de valider et d'évaluer les performances de chaque méthode proposée. Une étude détaillée a été réalisée dans le but d'évaluer chaque méthode dans l'application prévue. Nous présentons également les résultats et démontrons la sélection des caractéristiques dans un but de réduction de dimensionnalité, la classification, la régression, la détection des anomalies, la validation et la reconstruction des données anormales et manquantes et de la prédiction des doses optimales de coagulants et de l'indice de qualité de l'eau au sens des capteurs logiciels.

CONCLUSION GENERALE

Le travail présenté dans cette thèse a été consacré à la mise en œuvre des techniques d'apprentissage statistique appliquées à la reconnaissance de formes dans le domaine du contrôle, de surveillance et de diagnostic des systèmes de production des eaux propres en Algérie. Cette étude s'inscrit dans le cadre des progrès importants qui ont été enregistrés ces dernières années dans le but et l'intérêt d'une surveillance intelligente, moderne et plus efficace de la qualité des eaux propres. Les normes de qualité de l'eau sont de plus en plus strictes. Cette perspective raisonnable des consommateurs vis-à-vis les systèmes de distribution a incité les industriels de ce domaine à engager de nouveaux efforts de recherche pour garantir la performance de leurs appareils. A cet effet, notre modeste travail peut être considéré comme une contribution aux solutions proposées, pour résoudre des problèmes d'intérêt stratégique à préoccupation nationale, utilisant des outils intelligents à base de techniques modernes et avancées.

Les divers dispositifs et outils de surveillance et de diagnostic dans ce domaine existants actuellement dans le monde, sont réalisés dans le but d'assurer une surveillance permanente et efficace des installations des systèmes de production d'eau potable. C'est dans l'esprit et l'intérêt considérable que présente la surveillance de la qualité de l'eau dans les usines de production et de distribution, que nous avons tenté dans cette thèse d'exposer notre étude. Notre objectif est d'aboutir à une technique de contrôle et diagnostic bien adaptée qui soit apte à maîtriser la surveillance et la production de cette ressource précieuse de manière efficace, permanente et intelligente.

Cette étude a été structurée autour de quatre chapitres essentiels. Le premier consacré à une description générale non exhaustive de domaine de surveillance, de diagnostic et de supervision des systèmes de production, notamment qu'ils utilisent les techniques de surveillance et le diagnostic par Intelligence Artificielle (IA). On a plutôt détaillé la description de système de production d'eau et les différents paramètres relatifs à la qualité de l'eau potable en particulier. Dans le second, on a passé en revue des méthodes d'apprentissage automatique dans un but d'analyse de données appliquées à la réduction de

la dimension des variables d'entrée telles que : Analyse en Composantes Principales (ACP), les cartes auto-organisatrices de Kohonen (SOM), et la classification ascendante hiérarchique (CAH), qui est une méthode de classification automatique non supervisée. Le troisième chapitre a été particulièrement dédié aux méthodes de classification et de régression de données à apprentissage statistique supervisé. Dans ce chapitre, trois modèles (RNA, SVM et LSTM) fondés sur ce type d'apprentissage ont été exposés. Enfin le quatrième et dernier chapitre, a fait l'objet d'une étude en simulation concernant la mise en œuvre de ces méthodes d'apprentissage statistique supervisé et non supervisé appliqués dans le domaine du contrôle, de surveillance et de diagnostic des eaux potables. Cette étude a permis la validation et l'évaluation des performances de chacune des méthodes présentées. Plusieurs exemples et scénarios de validation sont prévus dans ce cadre, le contrôle de potabilité de l'eau en tant que problème de classification supervisée, la détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs par la classification non supervisée et la prédiction de la dose optimale du coagulant et l'indice de qualité de l'eau (IQE) par régression non linéaire ainsi que la sélection des caractéristiques en premier lieu à l'aide de deux techniques ACP et SOM. La notion de capteurs logiciels conçus dans le domaine comme étant un moyen intéressant pouvant remplacer des capteurs physiques, a été aussi présentée. Les deux bases de données réelle provenant de la station Tilesdit de la wilaya de Bouira et la station de Sidi Lahdjel (MAO lot 1) de barrage de Cheliff de Mostaganem sont appliquées, et ont montrées l'efficacité de l'approche.

Dans cette étude, la principale contribution est d'apprendre et de classer les données de la qualité de l'eau à l'aide des méthodes LSTM et SVM avec une sélection de caractéristiques basée sur SOM et ACP. Pour plus de performances de classification, nous avons utilisé deux méthodes de validation croisée à savoir : k-fold standard et Holdout, pour estimer les performances des modèles de classification utilisés ainsi que le choix des paramètres des fonctions noyaux dans l'utilisation de la techniques SVM. La détection des anomalies et la reconstruction des données manquantes ou invalides des capteurs par la classification non supervisée utilisant la classification ascendante hiérarchique (CAH) et la prédiction de la dose optimale du coagulant et l'indice de qualité de l'eau (IQE) par régression non linéaire au sens des capteurs logiciels comme étant des moyens intéressants pouvant remplacer des capteurs physiques, sont tout prévus dans ce cadre.

Il apparaît sur le plan décisionnel, les deux modèles (SVM et LSTM) obtiennent de bons résultats avec des taux de reconnaissance supérieurs à 98% dans les phases d'apprentissage et de test avec la sélection de caractéristiques. Le meilleur résultat d'apprentissage du modèle LSTM-SOM, est de 98,81 % de taux de reconnaissance, 99,02 % de sensibilité, 96,99 % de spécificité, 99,64 % de précision et 99,33 % de valeurs métriques de performances F1-Score sont obtenues. Le modèle SVM-SOM avec la paire appropriée ($d = 2$, $\gamma = 37,17$, $C = 30,03$), a un taux de reconnaissance, de 99,81 %, une sensibilité de 99,79 %, une spécificité de 100 %, une précision de 100 % et des performances métriques F1-Score de 99,90 %. Le modèle SVM-SOM nécessite moins de temps que le temps d'apprentissage et de test par rapport au modèle LSTM-SOM, ce qui lui confère l'avantage d'une intégration dans un système de contrôle dynamique. L'usage d'une analyse des données par ACP et SOM dans un but d'une réduction de dimensionnalité, a confirmé davantage cet intérêt. Les résultats de la classification ont clairement montré une précision et une sensibilité plus élevées pour les deux méthodes d'apprentissage supervisé. L'ajout de deux algorithmes SOM et ACP dans le cadre proposé a encore amélioré la précision de la classification. Ce résultat est important car il reflète un impact économique sur le coût global du système de surveillance (hors ligne et nombre réduit de capteurs). Les deux techniques de classification non supervisée SOM et CAH montrent le point clé du processus de détection des anomalies, validation et reconstruction des données manquantes ou invalides des capteurs et leurs résultats sont compétitifs. Il est montré que les mesures estimées d'un capteur identifié comme défaillant peuvent être reconstruites grâce à une extension de l'algorithme SOM. Le dosage optimal de coagulant prédit par le capteur logiciel construit par un modèle SVR proposée a une grande précision. La méthode RNA était capable de prédire avec succès l'IQE avec une grande précision. La précision de l'estimation dans les deux cas est confirmée par l'absence de valeurs aberrantes. Les performances ainsi obtenues peuvent être alors améliorées. En effet, une base de données réelle plus importante et plus significative, contribue sans doute à augmenter la précision de reconnaissance et de l'estimation. Ceci met évidemment en jeu le nombre et le type d'exemples à utiliser dans la base d'apprentissage. Comme souligné auparavant, la présence d'un expert (ou système expert) serait indispensable dans ce cas-là. Le temps correspondant à la phase d'entraînement reste relativement important, ce qui laisse envisager d'autres outils de calcul plus puissants afin d'améliorer les capacités et obtenir plus de performances. Le contrôle de potabilité peut par contre être pris en charge

de façon dynamique par le système de surveillance multi-capteur, puisque le temps d'exécution reste faible. Dans tous les cas, cette solution n'est pas définitive, un système de réapprentissage par des méthodes puissantes et très fiables devrait probablement être mené périodiquement afin que les situations qui pourraient survenir soient prises en compte et ajustées en permanence pour faire évoluer la qualité de l'eau. Ces techniques sont fortement recommandées pour être utilisées pour des évaluations précises, rapides et rentables de la qualité de l'eau pour tout système de production d'eau. Les horizons de notre application restent prometteurs. La décision du système peut être améliorée par l'exploitation de nouveaux paramètres d'entrée, d'autres méthodes avancées, plus puissantes et des bases de données plus importantes et significatives. Par conséquent, il est préférable d'utiliser une base de données plus étendue ou d'autres méthodes d'extrapolation de données comme la méthode EMD. L'utilisation de techniques de sélection de caractéristiques non linéaires peut aboutir à sélectionner des variables plus efficaces et ainsi améliorer la prise de décision. Les capteurs logiciels peuvent dans ce cas jouer un rôle primordial en se substituant davantage à des paramètres descripteurs chimiques ne pouvant être mesurés en continu. Il reste à noter que la sensibilité du domaine à des menaces imprévues, exige de plus grands efforts pour maximiser l'immunité du système et apporter d'autres améliorations afin de minimiser les risques encourus pour la santé publique. Enfin, cette application montre une alternative prometteuse pour notre pays dans l'avenir pour une surveillance intelligente et automatique de la qualité des eaux potables.

REFERENCES

- [1] M. Bouamar and M. Ladjal, "Performance evaluation of three pattern classification techniques used for water quality monitoring," *International Journal of Computational Intelligence and Applications*, vol. 11, no. 02, p. 1250013, Jun. 2012, doi: 10.1142/s1469026812500137.
- [2] Zahid Amjad and Peter G. Koutsoukos, "The science and technology of industrial water treatment: Mineral Scales and Deposits: An Overview", CRC Press, Taylor & Francis Group, Lubrizol Advanced Materials Inc., Brecksville, Ohio, USA, 2010. www.crcpress.com/product/isbn/9781420071443
- [3] Marie Cuq, "Eau : droit de l'homme ou marchandise ? Réflexion sur l'effectivité du droit de l'homme à l'eau", *Human Rights Abuses in the Contemporary World: Legal approaches*, Tbilissi : Géorgie, 2011. halshs.archives-ouvertes.fr
- [4] F. Valiron, "Gestion des Eaux : principes - moyens – structures", Presses de l'école nationale des ponts et chaussées, Paris, France, 1990.
- [5] "Les propriétés de développement social, L'eau potable", Document : ACIDI « Agence canadienne de développement international », 2004.
- [6] L. Hecini and S. Achour, "Coagulation-floculation au sulfate d'aluminium de composés organiques phénoliques et effet de sels de calcium et de magnésium," *Revue des sciences de l'eau*, vol. 27, no. 3, pp. 271–280, Dec. 2014, doi: 10.7202/1027810ar.
- [7] H. R. Hernández De León, "Supervision et diagnostic des procédés de production d'eau potable", Thèse de Doctorat, Institut National des Sciences Appliquées de Toulouse, CNRS, N° 06584, France, 2006.
- [8] W. Schon, K. Odeh, T. Denoex et F. Fotoohi, "Maîtrise des risques dans le domaine de l'eau potable", In Actes du 12ème Colloque National de Sûreté de Fonctionnement, Laboratoire SIME Système Intelligents pour la Maîtrise de l'Eau, Montpellier, 2000, France, pp. 695-701.
- [9] N. Valentin, "Construction d'un capteur logiciel pour le contrôle automatique du procédé de coagulation en traitement d'eau potable", Thèse de doctorat, UTC, Centre International de Recherche sur l'Eau et l'Environnement, CNRS, France, 2000.
- [10] R. Zemouri, D. Racoceanu, and N. Zerhouni, "Réseaux de neurones récurrents à fonctions de base radiales. Application à la surveillance dynamique," *Journal Européen des Systèmes Automatisés*, vol. 37, no. 1, pp. 49–81, Jan. 2003, doi: 10.3166/jesa.37.49-81.
- [11] N. Palluat, D. Racoceanu, and N. Zerhouni, "A neuro-fuzzy monitoring system," *Computers in Industry*, vol. 57, no. 6, pp. 528–538, Aug. 2006, doi: 10.1016/j.compind.2006.02.013.
- [12] R. Reyna Rojas, "Conception et intégration VLSI d'un système de vision générique, Application à la détection et la localisation d'objets à l'aide de "support vector machines"", Thèse de Doctorat, Institut National des Sciences Appliquées, Laboratoire LAAS/CNRS, N°02226, Toulouse, France, 2002.
- [13] Y. Liao, J. Xu, and W. Wang, "A Method of Water Quality Assessment Based on Biomonitoring and Multiclass Support Vector Machine," *Procedia Environmental Sciences*, vol. 10, pp. 451–457, 2011, doi: 10.1016/j.proenv.2011.09.074.
- [14] H. Yoon, Y. Hyun, K. Ha, K.-K. Lee, and G.-B. Kim, "A method to improve the stability and accuracy of ANN- and SVM-based time series models for long-term groundwater level predictions," *Computers & Geosciences*, vol. 90, pp. 144–155, May 2016, doi: 10.1016/j.cageo.2016.03.002.
- [15] H. Yoon, S.-C. Jun, Y. Hyun, G.-O. Bae, and K.-K. Lee, "A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer," *Journal of Hydrology*, vol. 396, no. 1–2, pp. 128–138, Jan. 2011, doi: 10.1016/j.jhydrol.2010.11.002.
- [16] P. J. G. Nieto, J. R. A. Fernández, V. M. G. Suárez, C. D. Muñiz, E. García-Gonzalo, and R. M. Bayón, "A hybrid PSO optimized SVM-based method for predicting of the cyanotoxin content from experimental cyanobacteria concentrations in the Trasona reservoir: A case study in Northern Spain," *Applied Mathematics and Computation*, vol. 260, pp. 170–187, Jun. 2015, doi: 10.1016/j.amc.2015.03.075.

- [17] L. Alzubaidi et al., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, no. 1, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [18] L. Khelifi and M. Mignotte, "Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis," *IEEE Access*, vol. 8, pp. 126385–126400, 2020, doi: 10.1109/access.2020.3008036.
- [19] Z. Li, F. Peng, B. Niu, G. Li, J. Wu, and Z. Miao, "Water Quality Prediction Model Combining Sparse Auto-encoder and LSTM Network," *IFAC-PapersOnLine*, vol. 51, no. 17, pp. 831–836, 2018, doi: 10.1016/j.ifacol.2018.08.091.
- [20] A. Widodo, B.-S. Yang, and T. Han, "Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors," *Expert Systems with Applications*, vol. 32, no. 2, pp. 299–312, Feb. 2007, doi: 10.1016/j.eswa.2005.11.031.
- [21] T. Li, G. Sun, C. Yang, K. Liang, S. Ma, and L. Huang, "Using self-organizing map for coastal water quality classification: Towards a better understanding of patterns and processes," *Science of The Total Environment*, vol. 628–629, pp. 1446–1459, Jul. 2018, doi: 10.1016/j.scitotenv.2018.02.163.
- [22] T. Voyslavov, S. Tsakovski, and V. Simeonov, "Surface water quality assessment using self-organizing maps and Hasse diagram technique," *Chemometrics and Intelligent Laboratory Systems*, vol. 118, pp. 280–286, Aug. 2012, doi: 10.1016/j.chemolab.2012.05.011.
- [23] Norme AFNOR X 60-000, "Maintenance industrielle – Fonction maintenance", Edition AFNOR, Paris, 2002.
- [24] Daniel Racoceanu, "Contribution à la surveillance des systèmes de production en utilisant les techniques de l'intelligence artificielle", Thèse d'HDR, Université de Franche-Comté de Besançon, France, N° d'ordre : 140, 2006.
- [25] Ryad Zemouri, "Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance". Thèse de doctorat, Automatique / Robotique. Université de Franche-Comté, 2003. N° ordre : 986.
- [26] Leger, J.-B., Introduction à l'e-maintenance, rapport de formation du personnel de la société DCN (Division des Constructions Navales) dans le cadre du contrat DCN Institut de Productique de Besançon, 2004.
- [27] Michele Basseville, Marie-Odile Cordier, Surveillance et diagnostic de systèmes dynamiques : approche complémentaire du traitement de signal et de l'intelligence artificielle, Rapport de recherche INRIA, N°2861, 1996.
- [28] Villemeur, A., Sûreté de fonctionnement des systèmes industriels, Edition Eyrolles, Collection DER-EDF, Volume 67, 1988.
- [29] Dubuisson, B., (). Diagnostic et reconnaissance des formes, Paris, Edition Hermès, 1990.
- [30] Combacau, M., Commande et Surveillance des Systèmes à Évènements Discrets Complexes : Application aux Ateliers Flexibles, Thèse de doctorat, Université Paul Sabatier, Toulouse, 1991.
- [31] Toguyeni, A.K.A., Surveillance et diagnostic en ligne dans les ateliers flexibles de l'industrie manufacturière, Thèse de doctorat, Université de Lille, 1992.
- [32] Zwingelstein, G., (). Diagnostic des défaillances : Théorie et pratique pour les systèmes industriels, Editions Hermès, 1995.
- [33] Lefebvre, D., (2000). Contribution à la modélisation des systèmes dynamiques à événements discrets pour la commande et la surveillance, Habilitation à Diriger des Recherches, Université de Franche Comté/ IUT Belfort - Montbéliard.
- [34] Ladjal Mohamed, "Contribution au développement de système de surveillance innovants dédiés au contrôle de la qualité des eaux potables", Thèse de doctorat, Université de M'sila, 2013.
- [35] A. T. Vemuri and M. M. Polycarpou, "Neural-network-based robust fault diagnosis in robotic systems," *IEEE Transactions on Neural Networks*, vol. 8, no. 6, pp. 1410–1420, Nov. 1997, doi: 10.1109/72.641464.
- [36] Nelly Olivier-Maget, "Surveillance des systèmes dynamiques hybrides", Thèse de Doctorat, Université de Toulouse, France, N° d'ordre : 913, 2007.

- [37] Aïmed Mokhtari, "Diagnostic des systèmes hybrides ; développement d'une méthode associant la détection par classification et la simulation dynamique", Thèse de Doctorat, Institut national des sciences appliquées de Toulouse, France, 2007.
- [38] Claudia Victoria Isaza Narvez, "Diagnostic par technique d'apprentissage floues ; conception d'une méthode de validation et d'optimisation des partitions", Thèse de Doctorat, Université de Toulouse, France, 2007.
- [39] S. Dash and V. Venkatasubramanian, "Challenges in the industrial applications of fault diagnostic systems," *Computers & Chemical Engineering*, vol. 24, no. 2–7, pp. 785–791, Jul. 2000, doi: 10.1016/S0098-1354(00)00374-4.
- [40] Combacau, M., *Commande et Surveillance des Systèmes à Événements Discrets Complexes : Application aux Ateliers Flexibles*, Thèse de doctorat, Université Paul Sabatier, Toulouse, 1991.
- [41] B. Dubuisson, E. Boutleux, P. Dague, T. Denoeux, E. Didelet, Y. Gandvalet et M. Masson, "Diagnostic, Intelligence artificielle et reconnaissance de formes", Edition Hermes, France, 2001.
- [42] Zwingelstein, G., *Diagnostic des défaillances : Théorie et pratique pour les systèmes industriels*, Editions Hermès, 1995.
- [43] Grosclaude, I., *Diagnostic Abductif Temporel : Scenarios de Pannes, modèles causaux et traitement de l'interaction*, Thèse de Doctorat, Université de Rennes 1, 2001a.
- [44] Bouchon-Meunier, B. et C. Marsala (). *Logique floue, principes, aide à la décision*, Ed. Hermes, 2003.
- [45] Katsillis, G., M.J. Chantler. Can dependency-based diagnosis cope with simultaneous equations?, Working notes of the 8th International Workshop on Principles of Diagnosis DX'97, Mont-Saint-Michel, France, 1997.
- [46] Loiez, E., *Contribution au diagnostic de systèmes analogique*, Thèse de doctorat de l'Université des sciences et technologies de Lille, 1997.
- [47] Washio, T. et H. Hotoda *Discovering admissible simultaneous equations of large scale systems*, 15th National Conference on Artificial Intelligence AAAI-98, Madison, WI, Etats-Unis, pp. 189-196, 1998.
- [48] Hines, J.W., D.W. Miller et B.K. Hajek. *Fault Detection and Isolation: A Hybrid Approach*, Proceedings of the 1995 American Nuclear Society Annual Meeting and Embedded Topical Meeting on Computer-Based Human Support Systems: Technology, Methods and Future, Philadelphia, PA, 1995.
- [49] A. T. Vemuri and M. M. Polycarpou, "Neural-network-based robust fault diagnosis in robotic systems," *IEEE Transactions on Neural Networks*, vol. 8, no. 6, pp. 1410–1420, Nov. 1997, doi: 10.1109/72.641464.
- [50] P. M. Frank, "Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy," *Automatica*, vol. 26, no. 3, pp. 459–474, May 1990, doi: 10.1016/0005-1098(90)90018-d.
- [51] Nicolas Pallaut, "Méthodologie de surveillance dynamique à l'aide des réseaux neuro-flous temporels", Thèse de Doctorat, Université de Franche-Comté de Besançon, France, N° d'ordre : 1135, 2006.
- [52] Igor Blîndu, "Outil d'aide au diagnostic du réseau d'eau potable pour la ville de Chisinau par analyse spatiale et temporelle des dysfonctionnements hydrauliques", Thèse de Doctorat, Ecole nationale supérieure des Mines de Saint-Etienne, Université Jean Monnet - Saint-Etienne, N° d'ordre : 336ID, France, 2004.
- [53] Chauvin Arnoux, "La production d'eau potable pilotée plus efficacement", *Informatique industrielle, Solutions, Mesures*, Vol. 840, Décembre 2011. www.mesures.com/archives/840-Sedif-production-eau.pdf
- [54] SA. Degrémont : « *Mémento Technique De L'eau - Tomes 2* ». Lavoisier - Technique et documentation, Paris, 2005. ISBN 13 : 9782743007171.
- [55] Degrémont, *Mémento Technique De L'eau : Tome 1*, Lavoisier - Technique et documentation, Paris, 1989.
- [56] Valiron F., *Gestion Des Eaux : Alimentation En Eau – Assainissement*, Presses de l'école nationale des ponts et chaussées, Paris, 1989.
- [57] Cardot C. *Les Traitements De L'eau. Procédés Physico-Chimiques Et Biologiques*. Ellipses Edition Marketing S.A., 1999.
- [58] Bertier, P., Bouroche, J.M., *Analyse des données multidimensionnelles*, PUF, 1975.

- [59] Pages, J.P., Cailliez, F., Escoufier, Y., (1979). Analyse factorielle : un peu d'histoire et de géométrie. *Revue de Statistique Appliquée*, Vol XXVII, n°1 pp. 5-28.
- [60] Chantal Saad Hajjar, Cartes auto-organisatrices pour la classification de données symboliques mixtes, de données de type intervalle et de données discrétisées, Thèse de Doctorat, école doctorale STITS Sciences et Technologies de l'Information, des télécommunications et des Systèmes, N° d'ordre : 2014-06-TH, France, 2014.
- [61] S. Johnson: Hierarchical clustering schemes. *Psychometrika*, 32(3):241–254, 1967.
- [62] J.C. Bezdek: *Pattern Recognition with Fuzzy Objective Function Algorithms*. Kluwer Academic Publishers, 1981. ISBN 0306406713.
- [63] E. Forgy : Cluster analysis of multivariate data : efficiency versus interpretability of classifications. *Biometrics*, 21:768–780, 1965.
- [64] J. B. MacQueen : Some Methods for Classification and Analysis of Multivariate Observations. In Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability, volume 1, pages 281–297. University of California Press, 1967.
- [65] E. Diday : La méthode des nuées dynamiques. *Revue de Statistique Appliquée*, 19(2):19–34, 1971.
- [66] L. Kaufman et P. Rousseeuw : *Clustering by Means of Medoids*. Reports of the Faculty of Mathematics and Informatics. Delft University of Technology. 1987.
- [67] I. T. Jolliffe, "Principal component analysis", Springer, 2nd edition, New York, USA, 2002.
- [68] J. L. Semmlow, "Biosignal and biomedical image processing", Marcel Dekker, New York, 2004.
- [69] Hamid R. Arabnia, "Software Tools And Algorithms For Biological Systems" Volume 696, Springer, 2011, USA.
- [70] H. Hernandez, "Développement d'un capteur logiciel pour la prédiction de la dose de coagulant dans une station de traitement d'eau potable en vue de son diagnostic", Rapport LAAS N° 05175, 6ème Congrès des Doctorats de l'Ecole Doctorat Systèmes (EDSYS), 17-20 Mai 2005, Toulouse, France.
- [71] Jean de Lagarde, "Initiation à l'analyse des données", Dunod, Paris, France, 1983.
- [72] Hala Najmeddine, "Méthode d'identification et de classification de la consommation d'énergie par usage en vue de l'intégration dans un compteur d'énergie électrique", Thèse de Doctorat, Université Blaise Pascal-Clermont II, France, N° d'ordre : D.U.1993, 2009.
- [73] C. Archaux, "Conception d'un système d'information dédiée à l'estimation de la valeur des clients en téléphonie mobile prépayée", Thèse de Doctorat, Université de Nantes, France, N° ED 366-193, 2005.
- [74] Sylvain Tertois, "Réduction des effets des non linéarités dans une modulation à l'aide de réseaux de neurones", Thèse de Doctorat, Université de Rennes 1, France, N° d'ordre : 2924, 2003.
- [75] Jolliffe, I.T. *Principal Component Analysis*. Springer-Verlag, New York, 1986.
- [76] [1]W. J. Krzanowski, "Selection of Variables to Preserve Multivariate Data Structure, Using Principal Components," *Applied Statistics*, vol. 36, no. 1, p. 22, 1987, doi: 10.2307/2347842.
- [77] W. J. Krzanowski, "A stopping rule for structure-preserving variable selection," *Statistics and Computing*, vol. 6, no. 1, pp. 51–56, Mar. 1996, doi: 10.1007/bf00161573.
- [78] Gower, J.C., *Statistical Methods of Comparing Different Multivariate Analyses of the Same Data*, Mathematics in the Archaeological and Historical Sciences), University Press, Edinburgh, 1971, 138-149.
- [79] Y. Lu, I. Cohen, X. S. Zhou, and Q. Tian, "Feature selection using principal feature analysis," *Proceedings of the 15th international conference on Multimedia - MULTIMEDIA '07*, 2007, doi: 10.1145/1291233.1291297.
- [80] Fraser, S. J., Dickson, B. L. "A New Method for Data Integration and Integrated Data Interpretation: Self-Organising Maps". *Data Visualization and Integration*. In "Proceedings of Exploration 07: Fifth Decennial International Conference on Mineral Exploration" edited by B. Milkereit, 2007, p. 907-910
- [81] D. Miljkovic, "Brief review of self-organizing maps," 2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), May 2017, doi: 10.23919/mipro.2017.7973581.

- [82] Tao Li, Guihua Sun, Chupeng Yang, Kai Liang, Shengzhong Ma, Lei Huang, "Using self-organizing map for coastal water quality classification: Towards a better understanding of patterns and processes" *Science of the Total Environment* 628–629 (2018) 1446–1459
- [83] A. Rauber, D. Merkl, and M. Dittenbach, "The growing hierarchical self-organizing map: exploratory analysis of high-dimensional data," *IEEE Transactions on Neural Networks*, vol. 13, no. 6, pp. 1331–1341, Nov. 2002, doi: 10.1109/tnn.2002.804221.
- [84] O. E. Dragomir, F. Dragomir, and M. Radulescu, "Matlab Application of Kohonen Self-organizing Map to Classify Consumers' Load Profiles," *Procedia Computer Science*, vol. 31, pp. 474–479, 2014, doi: 10.1016/j.procs.2014.05.292.
- [85] G. Breard, "Evaluating Self-Organizing Map Quality Measures as Convergence Criteria", doi: 10.23860/thesis-breard-gregory-2017.
- [86] Vercauteren, L., Sieben, G., Praet, M., Otte, G., Vingerhoeds, L., Boullart, L., Lalliauw, L., and Roeds, H., *The classification of brains tumours by a topological map*. In *Proceedings of ICNN*, Vol. 1, 387-391, Paris, 1990.
- [87] P. Elo, J. Saarinen, A. Värri, H. Nieminen, and K. Kaski, "Classification of Epileptic EEG by Using Self-Organizing Maps," *Artificial Neural Networks*, pp. 1147–1150, 1992, doi: 10.1016/b978-0-444-89488-5.50067-1.
- [88] O. Simula and A. Visa, "Self-Organizing Feature Maps in Texture Classification and Segmentation," *Artificial Neural Networks*, pp. 1621–1628, 1992, doi: 10.1016/b978-0-444-89488-5.50170-6.
- [89] Kohonen, T., Makisara, K. et Saramaki., T. Phonotopic maps - Insightfull representation phonological features for speech recognition. In *Proceedings of the 7th International Conference on Pattern Recognition*, 182-185, Montreal, 1984.
- [90] Koizumi, T., Vrata, J., et Taniguchi, S. A phoneme recognition using Self Organizing Feature Maps and hidden Markov models. In T. Kohonen, K. Makisara, Simula, and J. Kangas, editors, *Proceedings of ICANN91*, Vol. 1, 777-782, North Holland, 1991.
- [91] J. C. Scholtes, "Recurrent Kohonen Self-Organization in Natural Language Processing," *Artificial Neural Networks*, pp. 1751–1754, 1991, doi: 10.1016/b978-0-444-89178-5.50180-9.
- [92] H. J. Ritter, T. M. Martinetz, and K. J. Schulten, "Topology-conserving maps for learning visuo-motor-coordination," *Neural Networks*, vol. 2, no. 3, pp. 159–168, Jan. 1989, doi: 10.1016/0893-6080(89)90001-4.
- [93] T. M. Martinetz, H. J. Ritter, and K. J. Schulten, "Three-dimensional neural net for learning visuomotor coordination of a robot arm," *IEEE Transactions on Neural Networks*, vol. 1, no. 1, pp. 131–136, Mar. 1990, doi: 10.1109/72.80212.
- [94] Kohonen, T., Raivio, K., Simula, O, Nenta, O, et Enriksson, J. An adaptative discrete signal detector based on Self Organizing Maps. In *Proceedings of IJCNN*, Vol. 2, 249-252, Washington, 1990.
- [95] N. Doherty, H. Ritter, T. Martinetz, and K. Schulten, "Neural Computation and Self-Organising Maps: An Introduction.," *The Journal of the Operational Research Society*, vol. 45, no. 2, p. 240, Feb. 1994, doi: 10.2307/2584133.
- [96] M. Kasslin, J. Kangas, and O. Simula, "Process State Monitoring Using Self-Organizing Maps," *Artificial Neural Networks*, pp. 1531–1534, 1992, doi: 10.1016/b978-0-444-89488-5.50152-4.
- [97] Tryba V. et Goser K. Self-Organizing Feature Maps for process control in chemistry. In T. Kohonen, K. Makisara, O. Simula, and J. Kangas, editors, *Proceedings of ICANN91*, volume 1, pages 847-852. North Holland, 1991.
- [98] H. P. Siemon, "Selection of Optimal Parameters for Kohonen Self-organizing Feature Maps," *Artificial Neural Networks*, pp. 1573–1577, 1992, doi: 10.1016/b978-0-444-89488-5.50159-7.
- [99] Bradburn, "Reducing transmission error effects using a self-organizing network," *International Joint Conference on Neural Networks*, 1989, doi: 10.1109/ijcnn.1989.118294.
- [100] Kohonen T., Raivio K., Simula O., Nenta O., et Enriksson J. An adaptative discrete signal detector based on Self Organizing Maps. In *Proceedings of IJCNN*, volume 2, pages 249-52, Washington, 1990.
- [101] Badran F., Thiria S., et Main B. Lissage par carte topologique. In *Proceedings of NeuroNimes92*, Nîmes, November 1992.

- [102] Dubuisson, B. et Masson, M. A statistical decision rule with incomplete knowledge about classes, *Pattern Recognition*, 26(1), 155-165, 1993.
- [103] Hicham Chaoui, "conception et comparaison de lois de commande adaptative à base de réseaux de neurones pour une articulation flexible avec non-linéarité dure", mémoire présenté à l'université du québec à trois-rivières, 2002.
- [104] Jain, A.K. and Dubes, R.C. 1988. *Algorithms for Clustering Data*. Prentice Hall, 1988.
- [105] Y. Zhao, G. Karypis, and U. Fayyad, "Hierarchical Clustering Algorithms for Document Datasets," *Data Mining and Knowledge Discovery*, vol. 10, no. 2, pp. 141–168, Mar. 2005, doi: 10.1007/s10618-005-0361-3.
- [106] Claude Touzet, "Les Réseaux De Neurones Artificiels, Introduction Au Connexionnisme", Seconde édition, Editions la Machotte, France, 2016.
- [107] Mehdi Abadi, "Réalisation d'un réseau de neurones "SOM" sur une architecture matérielle adaptable et extensible à base de réseaux sur puce "NoC", Université de Lorraine, 2018.
- [108] Abdesslem Chamekh, "Optimisation des procédés de mise en forme par les réseaux de neurones artificiels", Thèse en cotutelle, Laboratoire en Sécurité de fonctionnement, Qualité et Organisation Institut des Sciences et Techniques de l'Ingénieur d'Angers, France, 2007.
- [109] Mina Kalakh, "Modélisation avec les réseaux de neurones d'un canal UWB dans un environnement minier souterrain", Mémoire présenté comme exigence partielle de la maîtrise en ingénierie, Université du Québec en Abitibi-Témiscamingue, 2013.
- [110] Brakni, El Mahdi, Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM. (Mémoire de maîtrise). Université du Québec en Abitibi-Témiscamingue. 2011, <https://depositum.uqat.ca/id/eprint/32>.
- [111] Chaoui, Hicham, Conception et comparaison de lois de commande adaptative à base de réseaux de neurones pour une articulation flexible avec non-linéarité dure. Mémoire. Trois-Rivières, Université du Québec à Trois-Rivières, 2002.
- [112] N. Palluat, D. Racoceanu, and N. Zerhouni, "Utilisation des réseaux de neurones temporels pour le pronostic et la surveillance dynamique. Etude comparative de trois réseaux de neurones récurrents," *Revue d'intelligence artificielle*, vol. 19, no. 6, pp. 913–950, Dec. 2005, doi: 10.3166/ria.19.913-950.
- [113] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [114] J. Heaton, "Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning," *Genetic Programming and Evolvable Machines*, vol. 19, no. 1–2, pp. 305–307, Oct. 2017, doi: 10.1007/s10710-017-9314-z.
- [115] L. Alzubaidi et al., "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, vol. 8, no. 1, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [116] V. N. Vapnik, "The Nature of Statistical Learning Theory," 1995, doi: 10.1007/978-1-4757-2440-0.
- [117] Anis Ben Ishak, "Sélection de variables par les machines à vecteurs de support pour la discrimination binaire et multiclasse en grande dimension", Thèse de Doctorat, Université de Tunis, Tunisie, 2007.
- [118] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*, 1992, doi: 10.1145/130385.130401.
- [119] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/bf00994018.
- [120] Y. Guermeur and H. Paugam-Moisy, "Théorie de l'apprentissage de Vapnik et SVM, support vector machines", In M. Sebban and G. Venturini, editors, *Apprentissage Automatique*, Edition Hermès, 1999, pp. 109-138.
- [121] P. Mahé, "Noyaux pour graphes et Support Vector Machines pour le criblage virtuel de molécules", Rapport de stage, DEA en Mathématiques, Ecole Normale Supérieure de Cachan, France, 2003.

- [122] B. Scholkopf et al., "Comparing support vector machines with Gaussian kernels to radial basis function classifiers," *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2758–2765, 1997, doi: 10.1109/78.650102.
- [123] J. Callut, "Implémentation efficace des support vector machines pour la classification", Mémoire de grade de Maître en informatique, Université libre de Bruxelles, Belgique, 2003.
- [124] S. R. Gunn, "Support vector machines for classification and regression", Technical Report ISIS-1-98, Department of Electronics and Computer Science, University of Southampton, UK, 1998.
- [125] I. AICHE, M. KETFI, "Machines D'apprentissage Puissantes Pour La Reconnaissance Des Formes." Mémoire pour l'obtention Du diplôme de Master Académique. Univ. Msila, 2018.
- [126] Chen Junli and Jiao Licheng, "Classification mechanism of support vector machines," *WCC 2000 - ICSP 2000. 2000 5th International Conference on Signal Processing Proceedings. 16th World Computer Congress 2000*, doi: 10.1109/icosp.2000.893396.
- [127] H. Majdoulayne, "Extraction de caractéristiques de texture pour la classification d'image satellites", Thèse de Doctorat, Université de Paul Sabatier, Toulouse III, France, 2009.
- [128] A. J. Smola, P. Bartlett, B. Schölkopf, and D. Schuurmans, Eds., "Advances in Large-Margin Classifiers," 2000, doi: 10.7551/mitpress/1113.001.0001.
- [129] A. Cornuéjols, "Une nouvelle méthode d'apprentissage : Les SVM, Séparateurs à vaste marge", *Bulletin de l'AFIA*, N° 51, Université de Paris-Sud, Orsay, France, 2002.
- [130] S. Canu, "Machines à noyaux pour l'apprentissage statistique", *Techniques d'ingénieur*, TE 5 255, 2007.
- [131] S. Borovkova and I. Tsiamas, "An ensemble of LSTM neural networks for high-frequency stock market classification," *Journal of Forecasting*, vol. 38, no. 6, pp. 600–619, May 2019, doi: 10.1002/for.2585.
- [132] C. Hu et al., "LSTM-RNN-based defect classification in honeycomb structures using infrared thermography," *Infrared Physics & Technology*, vol. 102, p. 103032, Nov. 2019, doi: 10.1016/j.infrared.2019.103032.
- [133] Ikram Chraïbi Kaadoud, "Apprentissage de séquences et extraction de règles de réseaux récurrents : application au traçage de schémas techniques". Thèse PhD, Laboratoire Bordelais de Recherche en Informatique, INRIA Bordeaux, France, 2018
- [134] Lapalme Jasmin, "Composition automatique de musique à l'aide de réseaux de neurones récurrents et de la structure métrique", Mémoire de Maître ès sciences en informatique, Université de Montréal, 2005.
- [135] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to Forget: Continual Prediction with LSTM," *Neural Computation*, vol. 12, no. 10, pp. 2451–2471, Oct. 2000, doi: 10.1162/089976600300015015.
- [136] Smail Dilmi, "Contribution à l'amélioration de décision et de diagnostic des systèmes industriels de production en utilisant l'intelligence artificielle", Thèse de doctorat, Université de M'sila, 2022.
- [137] M. I. Khelil, M. Ladjal, Y. Brik, M. A. Ouali, "Self-Organizing Maps-Based Features Selection with Deep LSTM and SVM Classification Approaches for Advanced Water Quality Monitoring", *International Journal of Intelligent Engineering and Systems*, vol. 15, No. 3, pp. 90–102, June, 2022, doi: 10.22266/ijies2022.0630.09.
- [138] M. I. Khelil, M. Ladjal, M. A. Ouali, H. Bennacer, "Sensor Anomaly Detection using Self Features Organizing Maps and Hierarchical-Clustering for Water Quality Assessment", *The International Conference of advanced Technology in Electronic and Electrical Engineering, ICATEEE 2022*, 26-27 November 2022, M'sila, Algeria.
- [139] M. I. Khelil, M. Ladjal, M. A. Ouali, H. Bennacer, M. Djerioui, "Soft Sensing Modeling Based on Support Vector Machine and Self-Organizing Maps Model Selection for Water Quality Monitoring", *The International Conference of advanced Technology in Electronic and Electrical Engineering, ICATEEE 2022*, 26-27 November 2022, M'sila, Algeria.
- [140] M. I. Khelil, M. Ladjal, "Hybrid Predictive Models for Water Quality Assessment Based on Water Quality Index Using ANN, LSSVM and multivariate statistical Methods", *Online 9th international conference on applied analysis and mathematical modelling (ICAAMM2021)*, June 11 -13, 2021, Istanbul, Turkey.

- [141] Abousoufyane Slatnia, M. Ladjal, M. A. Ouali, M. I. Khelil, "Improving Prediction and Classification of Water Quality Index Using Hybrid Machine-Learning Algorithms with Features Selection Analysis", international symposium on applied mathematics and engineering, January 21-23, 2022, Biruni University, Istanbul-Turkey.
- [142] N. Bhardwaj, P. M. Kim, and M. B. Gerstein, "Rewiring of Transcriptional Regulatory Networks: Hierarchy, Rather Than Connectivity, Better Reflects the Importance of Regulators," *Science Signaling*, vol. 3, no. 146, Nov. 2010, doi: 10.1126/scisignal.2001014.
- [143] O. Ayeni, "Risk Assessment of Raw Effluents Discharged From an Industrial Estate in Lagos, Southwestern Nigeria," *Greener Journal of Environmental Management and Public Safety*, vol. 2, no. 5, pp. 189–194, Sep. 2013, doi: 10.15580/gjemps.2013.5.110113939.
- [144] D. Liu and Z. Zou, "Water quality evaluation based on improved fuzzy matter-element method," *Journal of Environmental Sciences*, vol. 24, no. 7, pp. 1210–1216, Jul. 2012, doi: 10.1016/s1001-0742(11)60938-8.
- [145] L. K. Wang, B. H. Men, Q. Fu, T. G. Lu, "Matter element model for evaluating the water quality pollution", *System Sciences and Comprehensive Studies in Agriculture*, 2004, Vol. 20, N° 2, pp. 96-98.
- [146] Z. ZOU, Y. YUN, and J. SUN, "Entropy method for determination of weight of evaluating indicators in fuzzy synthetic evaluation for water quality assessment," *Journal of Environmental Sciences*, vol. 18, no. 5, pp. 1020–1023, Sep. 2006, doi: 10.1016/s1001-0742(06)60032-6.
- [147] L. Zhang, G. X. Wang, M. R. Luo, "Application of an improved grey association analysis method in water environmental quality assessment", *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2004, Vol. 43, N° 21, pp. 234-236.
- [148] J. L. Jin, L. Liu, J. Ding, Q. Fu, "Logistic curve model of groundwater quality evaluation", *Environmental Pollution and Control*, 2003, Vol. 25, N° 1, pp. 46-48.
- [149] L. J. Wang, Z. H. Zou, "Application of improved attributes recognition method in water quality assessment", *Chinese Journal of Environmental Engineering*, 2008, Vol. 2, N° 4, pp. 553-556.
- [150] S. Areerachakul and S. Sanguansintukul, "Classification and Regression Trees and MLP Neural Network to Classify Water Quality of Canals in Bangkok, Thailand," *International Journal of Intelligent Computing Research*, vol. 1, no. 2, pp. 30–37, Jun. 2010, doi: 10.20533/ijicr.2042.4655.2010.0004.
- [151] H. Yan, Z. Zou, and H. Wang, "Adaptive neuro fuzzy inference system for classification of water quality status," *Journal of Environmental Sciences*, vol. 22, no. 12, pp. 1891–1896, Dec. 2010, doi: 10.1016/s1001-0742(09)60335-1.
- [152] Décret exécutif N° 09-414 du 28 Dhou El Hidja 1430 correspondant au 15 décembre 2009 fixant : "la nature, la périodicité et les méthodes d'analyse de l'eau de consommation humaine", *Journal officiel de la République Algérienne N°75*, 20 décembre 2009.
- [153] Décret exécutif N° 11-125 du 17 Rabie Ethani 1432 correspondant au 22 mars 2011 relatif à : "la qualité de l'eau de consommation humaine", *Journal officiel de la République Algérienne N°18*, 23 mars 2011.
- [154] S. Chauhan, L. Vig, and S. Ahmad, "ECG anomaly class identification using LSTM and error profile modeling," *Computers in Biology and Medicine*, vol. 109, pp. 14–21, Jun. 2019, doi: 10.1016/j.combiomed.2019.04.009.
- [155] O. Yildirim, U. B. Baloglu, R.-S. Tan, E. J. Ciaccio, and U. R. Acharya, "A new approach for arrhythmia classification using deep coded features and LSTM networks," *Computer Methods and Programs in Biomedicine*, vol. 176, pp. 121–133, Jul. 2019, doi: 10.1016/j.cmpb.2019.05.004.
- [156] M. Toğaçar, B. Ergen, and Z. Cömert, "Waste classification using AutoEncoder network with integrated feature selection method in convolutional neural network models," *Measurement*, vol. 153, p. 107459, Mar. 2020, doi: 10.1016/j.measurement.2019.107459.
- [157] S. Kundu and S. Ari, "P300 based character recognition using sparse autoencoder with ensemble of SVMs," *Biocybernetics and Biomedical Engineering*, vol. 39, no. 4, pp. 956–966, Oct. 2019, doi: 10.1016/j.bbe.2019.08.001.
- [158] I. Saini, D. Singh, and A. Khosla, "QRS detection using K-Nearest Neighbor algorithm (KNN) and evaluation on standard ECG databases," *Journal of Advanced Research*, vol. 4, no. 4, pp. 331–344, Jul. 2013, doi: 10.1016/j.jare.2012.05.007.

- [159] H. Shao, H. Jiang, H. Zhao, and F. Wang, "A novel deep autoencoder feature learning method for rotating machinery fault diagnosis," *Mechanical Systems and Signal Processing*, vol. 95, pp. 187–204, Oct. 2017, doi: 10.1016/j.ymssp.2017.03.034.
- [160] A. Najah Ahmed et al., "Machine learning methods for better water quality prediction," *Journal of Hydrology*, vol. 578, p. 124084, Nov. 2019, doi: 10.1016/j.jhydrol.2019.124084.
- [161] M. Djerioui, M. Bouamar, M. Ladjal, and A. Zerguine, "Chlorine Soft Sensor Based on Extreme Learning Machine for Water Quality Monitoring," *Arabian Journal for Science and Engineering*, vol. 44, no. 3, pp. 2033–2044, Apr. 2018, doi: 10.1007/s13369-018-3253-8.
- [162] B. Lamrini, E.-K. Lakhel, M.-V. Le Lann, and L. Wehenkel, "Data validation and missing data reconstruction using self-organizing map for water treatment," *Neural Computing and Applications*, vol. 20, no. 4, pp. 575–588, Feb. 2011, doi: 10.1007/s00521-011-0526-5.
- [163] Y. Zhang, C.M. Bingham and M. Gallimore, *Applied Sensor Fault Detection, Identification and Data Reconstruction, AiMT Advances in Military Technology Vol. 8, No. 2, December 2013*, doi.org/10.3849/aimt.01002
- [164] W. Fan, F. Si, S. Ren, C. Yu, Y. Cui, and P. Wang, "Integration of continuous restricted Boltzmann machine and SVR in NOx emissions prediction of a tangential firing boiler," *Chemometrics and Intelligent Laboratory Systems*, vol. 195, p. 103870, Dec. 2019, doi: 10.1016/j.chemolab.2019.103870.
- [165] P. Jain, I. Rahman, and B. D. Kulkarni, "Development of a Soft Sensor for a Batch Distillation Column Using Support Vector Regression Techniques," *Chemical Engineering Research and Design*, vol. 85, no. 2, pp. 283–287, Jan. 2007, doi: 10.1205/cherd05026.
- [166] R. M. Brown, N. I. McClelland, R. A. Deininger, and M. F. O'Connor, "A Water Quality Index – Crashing The Psychological Barrier," *Advances in Water Pollution Research*, pp. 787–797, 1973, doi: 10.1016/b978-0-08-017005-3.50067-0.
- [167] Chatterjee, C. and Raziuddin, M., Determination of water quality index of a degraded river in Asanol Industrial area, Raniganj, Burdwan, West Bengal, *Nature, Environment and Pollution Technology*, 1 (2), 2002, pp 181-189? 2002
- [168] Aher, D. N., Kele, V. D., Malwade, K. D., & Shelke, M. D., Lake Water Quality Indexing To Identify Suitable Sites For Household Utility: A Case Study Jambhulwadi Lake; Pune (MS). *Int. Journal of Engineering Research and Applications*, 6(5), (pp.16-21), 2016.

Résumé : L'objectif des travaux de développement des outils de surveillance/diagnostic /contrôle d'un système de production d'eau dans son ensemble est la maîtrise de la qualité de l'eau et la diminution des contraintes de coût de fonctionnement, objet d'une réglementation très stricte des pouvoirs publics. L'établissement de modèles du comportement des systèmes est un problème incontournable en automatique. D'importants efforts dans le développement de méthodes de contrôle, de diagnostic et de surveillance automatique ont été effectués durant ces dernières années. Le présent travail s'inscrit dans ce courant de recherche, en proposant une nouvelle approche de la surveillance et de diagnostic de systèmes de production d'eau propre en fonction des caractéristiques intrinsèques à l'aide d'un modèle basé sur les techniques avancées d'intelligence artificielle. La préparation de la base de données dans ce type d'application consiste à retenir les variables les plus représentatives des données observées. Elle peut être utile comme étape préliminaire à tout processus d'analyse et de classification ou régression afin de se concentrer sur les variables les plus importantes et réduire le coût d'exécution d'un tel processus.

L'objectif recherché dans ce travail, est une contribution à l'étude, à la conception, et au développement de nouveaux systèmes intelligents de contrôle, de diagnostic et de surveillance de la qualité de l'eau propre par reconnaissance de formes. Il consiste à la recherche d'une validation et évaluation complète expriment les variables indicatrices de système de production choisi pour l'aide à la décision. Cette décision est basée sur l'application des techniques de l'intelligence artificielle de deux zones d'étude en Algérie. L'intérêt principal du système réside dans sa capacité à prendre en compte diverses sources d'incertitude, telles que des données d'entrées atypiques, des erreurs de mesure et la taille limitée de l'ensemble d'apprentissage. Des résultats expérimentaux sont présentés et montrent l'efficacité de cette approche. Plusieurs exemples d'application sont prévus à cet effet : la sélection des caractéristiques, le développement des capteurs logiciels et la prédiction de l'indice de qualité vu comme des problèmes de régression, et le contrôle de potabilité de l'eau et la détection des anomalies et la reconstruction des données manquantes ou invalides en tant que problème de classification.

Abstract : The objective of development work on monitoring/diagnosis/control tools for a water production system as a whole is to control water quality and reduce operating cost constraints, subject to regulations. very strict government. The establishment of models of the behavior of systems is an unavoidable problem in automatic control. Significant efforts in the development of automatic control, diagnosis and monitoring methods have been made in recent years. The present work is part of this current of research, by proposing a new approach to the monitoring and diagnosis of clean water production systems according to the intrinsic characteristics using a model based on advanced techniques of 'artificial intelligence. The preparation of the database in this type of application consists in retaining the variables most representative of the observed data. It can be useful as a preliminary step to any analysis and classification or regression process in order to focus on the most important variables and reduce the cost of performing such a process.

The objective sought in this work is a contribution to the study, design and development of new intelligent systems for the control, diagnosis and monitoring of clean water quality by pattern recognition. It consists in the search for a validation and complete evaluation express the indicator variables of the production system chosen for decision support. This decision is based on the application of artificial intelligence techniques from two study areas in Algeria. The main interest of the system lies in its ability to take into account various sources of uncertainty, such as atypical input data, measurement errors and the limited size of the training set. Experimental results are presented and show the effectiveness of this approach. Several application examples are provided for this purpose: the selection of characteristics, the development of soft sensors and water quality index prediction seen as a regression problems, and the control of water potability and the detection of anomalies and the reconstruction of missing or invalid data. as a classification problem.

ملخص : هدف من أعمال التطوير الخاصة بأدوات المراقبة / التشخيص لنظام إنتاج المياه ككل هو التحكم في جودة المياه وتقليل قيود تكلفة التشغيل، وفقاً للوائح .حكومة صارمة للغاية .يعد إنشاء نماذج لسلوك الأنظمة مشكلة لا مفر منها في التحكم الآلي .بُذلت جهود كبيرة في تطوير أساليب التحكم الآلي والتشخيص والرصد في السنوات الأخيرة .العمل الحالي هو جزء من هذا البحث الحالي، من خلال اقتراح نهج جديد لرصد وتشخيص أنظمة إنتاج المياه النظيفة وفقاً للخصائص الجوهرية باستخدام نموذج يعتمد على التقنيات المتقدمة للذكاء الاصطناعي .يتكون إعداد قاعدة البيانات في هذا النوع من التطبيقات من الاحتفاظ بالمتغيرات الأكثر تمثيلاً للبيانات المرصودة .يمكن أن تكون مفيدة كخطوة أولية لأي تحليل وتصنيف أو عملية انحدار من أجل التركيز على أهم المتغيرات وتقليل تكلفة تنفيذ مثل هذه العملية .الهدف المنشود من هذا العمل هو المساهمة في دراسة وتصميم وتطوير أنظمة ذكية جديدة للتحكم في جودة المياه النظيفة وتشخيصها ومراقبتها من خلال التعرف على الأنماط .وهو يتألف من البحث عن التحقق والتقييم الكامل للتعبير عن متغيرات المؤشر لنظام الإنتاج المختار لدعم القرار .يعتمد هذا القرار على تطبيق تقنيات الذكاء الاصطناعي من منطقتين دراسيتين في الجزائر .يكمن الاهتمام الرئيسي للنظام في قدرته على مراعاة مصادر عدم اليقين المختلفة، مثل بيانات الإدخال غير النمطية وأخطاء القياس والحجم المحدود لمجموعة التدريب . يتم عرض النتائج التجريبية وتظهر فعالية هذا النهج .تم تقديم العديد من الأمثلة التطبيقية لهذا الغرض: اختيار الخصائص، تطوير أجهزة الاستشعار اللينة والتنبؤ بمؤشر جودة المياه يعتبر من مشاكل الانحدار ، والتحكم في صلاحية المياه للشرب واكتشاف الحالات الشاذة وإعادة بناء البيانات المفقودة أو غير الصالحة .كمشكلة تصنيف.