

# Université Mohamed Boudiaf - M'sila

FACULTE DE TECHNOLOGIE  
DEPARTEMENT DE GENIE ELECTRIQUE



Numéro de série : 01/D3C/D.GE/F.T/2022

Numéro d'inscription : D.AUT/3C/05/18

## Thèse

Présentée pour l'obtention du diplôme de

### DOCTORAT TROISIEME CYCLE

Filière : Automatique

Spécialité : Automatique et informatique industrielle

#### THEME

## Contribution à l'amélioration de décision et de diagnostic des systèmes industriels de production en utilisant l'intelligence artificielle

Présentée par

**DILMI Smail**

Soutenue le : **04/01/2022** devant le jury composé de :

<b>ZEGHLACHE Samir</b>	<b>Professeur – Université Mohamed Boudiaf - M'sila</b>	<b>Président</b>
<b>LADJAL Mohamed</b>	<b>Professeur – Université Mohamed Boudiaf - M'sila</b>	<b>Rapporteur</b>
<b>BENYETTOU Loufï</b>	<b>M.C.A – Université Mohamed Boudiaf - M'sila</b>	<b>Examineur</b>
<b>BRIK Youcef</b>	<b>M.C.A – Université Mohamed Boudiaf - M'sila</b>	<b>Examineur</b>
<b>CHERROUN Lakhmissi</b>	<b>M.C.A – Université Ziane Achour - Djelfa</b>	<b>Examineur</b>
<b>LATRECHE Samia</b>	<b>M.C.A – Université Ferhat Abbas – Sétif 1</b>	<b>Examineur</b>

# ***DEDICACE***

*Je dédie ce modeste travail*

*A mes très chers parents, que ALLAH les garde et les protège pour leurs soutien moral et financier, pour leurs encouragements et les sacrifices qu'ils ont endurés.*

*A mes sœurs et mes frères et A toute ma famille de près ou de loin.*

*A tous mes amis.*

*Smail Dilmi*

# ***REMERCIEMENTS***

Au terme de ce travail, je voudrais d'abord remercier Dieu de m'avoir donné force, courage et patience pour faire ce travail de la meilleure façon possible.

Je tiens à exprimer ma profonde gratitude et mes plus vifs remerciements à mon directeur de thèse **Prof. LADJAL Mohamed** Professeur de l'Université Mohamed Boudiaf - M'sila, pour ses précieux conseils et son grand soutien.

Mes remerciements vont également aux membres du jury : le **Prof. ZEGHLACHE Samir** Professeur de l'Université Mohamed Boudiaf - M'sila, pour avoir accepté très aimablement de présider mon jury de soutenance, aux : **Dr. BENYETTOU Loutfi** Maître de conférences (A) de l'Université Mohamed Boudiaf - M'sila, **Dr. BRIK Youcef** Maître de conférences (A) de l'Université Mohamed Boudiaf - M'sila, **Dr. CHERROUN Lakhmissi** Maître de conférences (A) de l'Université Ziane Achour - Djelfa et **Mme Dr. LATRECHE Samia** Maître de conférences (A) de l'Université Ferhat Abbas – Sétif 1, pour l'honneur qu'ils m'ont fait en acceptant d'examiner et de juger objectivement ce travail de recherche.

Je tiens également à remercier tous ceux qui m'ont soutenu de près ou de loin.

# TABLE DES MATIERES

DEDICACES	i
REMERCIEMENTS	ii
TABLE DES MATIERES	iii
RESUME	vii
ABREVIATIONS ET NOTATIONS	viii
LISTE DES FIGURES	xi
LISTE DES TABLEAUX	xiii
INTRODUCTION GENERALE	1

## *CHAPITRE I*

### **SURVEILLANCE DES PROCESSUS DE PRODUCTION D'EAU POTABLE**

Introduction	6
1. Définition de l'eau potable	6
1.1.Types des eaux propres	7
1.1.1. L'eau minérale naturelle	7
1.1.2. L'eau de source	7
1.1.3. L'eau traitée	8
2. Caractéristiques de l'eau	8
2.1.Caractéristiques physiques de l'eau	9
2.1.1. Turbidité	9
2.1.2. Couleur	9
2.1.3. Goût et odeur	9
2.1.4. Température	9
2.1.5. Conductivité	10
2.1.6. Teneur totale en solides	10
2.2.Caractéristiques chimiques de l'eau	10
2.2.1. pH	10
2.2.2. Salinité	11

2.2.3. Oxygène dissous (DO)	11
2.2.4. La demande biologique en oxygène (DBO)	11
2.2.5. La demande chimique en oxygène (DCO)	11
2.2.6. Les nutriments	12
2.2.6.1. Composés azotés	12
2.2.6.2. Composés du phosphore	13
2.3. Caractéristiques biologiques	13
2.3.1. Contamination microbienne	13
2.3.2. Coliformes totaux et coliformes fécaux	13
3. Le traitement de l'eau	13
3.1. Chaîne de traitement	14
3.1.1. Prétraitement	15
3.1.2. Pré-oxydation	16
3.1.2.1. Pré-oxydation au chlore	16
3.1.2.2. Pré-oxydation au dioxyde de chlore	16
3.1.2.3. Pré-oxydation au permanganate de potassium	17
3.1.2.4. Pré-oxydation à l'ozone	17
3.1.3. Clarification	18
3.1.3.1. Étapes de clarification	18
3.1.4. Désinfection	19
3.1.5. Affinage	20
4. La surveillance de la qualité des eaux	21
4.1. Méthodes de surveillance	21
4.1.1. Méthodes sans modèle	23
4.1.2. Méthodes à base de modèle	24
Conclusion	25

## *CHAPITRE II*

### **REDUCTION DE DIMENSIONNALITE**

Introduction	26
1. Problème avec de nombreuses variables d'entrée	26

2. Techniques de réduction de dimensionnalité	27
2.1.Extraction de caractéristiques	27
2.1.1. Analyse en composantes principales	28
2.1.2. Analyse discriminante linéaire	33
2.1.2.1.Définition	33
2.1.2.2.Algorithme LDA	37
2.1.3. Analyse en composantes indépendantes	40
2.1.3.1.Phase de prétraitement	41
2.1.3.2.Principe de l'estimation ICA	43
2.1.3.3.Algorithmes ICA	45
2.2.Sélection de caractéristiques	47
Conclusion	48

### *CHAPITRE III*

## **METHODES D'APPRENTISSAGE AUTOMATIQUE**

Introduction	50
1. Réseau de neurones récurrents	50
1.1.Long Short Term Memory (LSTM)	53
2. Machines à vecteurs de support (SVM)	55
2.1.SVM binaire	55
2.2. SVM multi-classes	60
3. Machine d'apprentissage extrême	62
Conclusion	64

### *CHAPITRE IV*

## **SIMULATION ET EVALUATION**

Introduction	66
1. Problématique	66
1.1.Le système de surveillance de la qualité de l'eau à multi-capteurs proposé	66
1.2.Description des données d'entrée	68
2. Résultats et discussion	70
2.1.Sélection de variables	71

2.1.1. Sélection de variables avec PCA	72
2.1.2. Sélection de variables avec LDA	76
2.1.3. Sélection de variables avec ICA	78
2.2.Processus d'apprentissage et de classification	83
2.2.1. Classification utilisant LSTM RNN	87
2.2.2. Classification utilisant SVM multi-classes	89
2.2.3. Classification utilisant ELM	91
2.3.Analyse et évaluation	92
Conclusion	93
CONCLUSION GENERALE	94
REFERENCES	97

# RESUME

Le contrôle de la qualité de l'eau joue un rôle essentiel dans la protection des ressources en eau, la gestion de l'environnement et la prise de décision. Cependant, les risques accrus de contamination rendent le processus de surveillance utilisant les méthodes traditionnelles plus complexe, difficile et coûteux. De nos jours, l'utilisation de procédés automatisés est devenue une nécessité dans le domaine du traitement de l'eau afin de réaliser un contrôle de qualité et de réduire les coûts d'exploitation. Ces dernières années, de nombreuses études se sont concentrées sur la création et le développement de nouvelles techniques de contrôle et de surveillance automatiques de la qualité de l'eau. Parmi ces techniques, nous citons LSTM RNN, SVM et ELM. Ces techniques se démarquent de plusieurs avantages par rapport aux autres grâce à leurs capacités d'apprentissage et de généralisation.

L'objectif de cette étude est de développer un modèle intelligent basé sur l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) et de techniques d'apprentissage automatique (LSTM RNN, SVM et ELM). Cette thèse présente l'application des techniques de l'intelligence artificielle pour améliorer la décision et le diagnostic des systèmes de production et de surveillance automatique de la qualité de l'eau propre. Plusieurs modèles ont été mis en œuvre et une étude comparative a été menée afin de choisir le modèle le plus approprié pour la possibilité de l'intégrer en temps réel dans un système de surveillance dynamique de la qualité de l'eau. Ces modèles ont été construits à partir des données historiques des paramètres physico-chimiques collectées à la station du barrage de Tilesdit à Bouira (Algérie) pendant une période de trois ans. En général, les résultats de la simulation ont montré que l'approche proposée a une performance très satisfaisante. Notre contribution dans ce modeste travail peut alors être considérée comme une solution adéquate qui permet de résoudre des problèmes d'importance stratégique régionale, nationale et internationale liés à la qualité de l'eau, en utilisant des nouveaux outils basés sur des technologies avancées.

**Mots clés** : Eau propre, Contrôle de la qualité de l'eau, Intelligence artificielle, Apprentissage automatique, Réduction de dimensionnalité, Classification, Barrage de Tilesdit.

## ABREVIATIONS ET NOTATIONS

**TU** : Turbidité

**mg/l** : Milligrammes par litre

**ppm** : Partie par million

**T** : Température

**EC** : Conductivité électrique

**μS/cm** : Micro-Siemens par centimètre

**SDT** : Solides dissous totaux

**pH** : Potentiel d'Hydrogène

**DO** : Oxygène dissous

**DBO** : Demande biologique en oxygène

**DCO** : Demande chimique en oxygène

**NO<sub>3</sub><sup>-</sup>** : Nitrate

**NO<sub>2</sub><sup>-</sup>** : Nitrite

**NH<sub>4</sub><sup>+</sup>** : L'ion ammonium

**N<sub>2</sub>** : L'azote moléculaire

**NH<sub>3</sub>** : L'ammoniac

**ClO<sub>2</sub><sup>-</sup>** : Chlorite

**KMnO<sub>4</sub>** : Le permanganate de potassium

**Cl<sub>2</sub>** : Chlore

**ClO<sub>2</sub>** : Dioxyde de chlore

**O<sub>3</sub>** : Ozone

**UV** : Lumière ultraviolette

**WQI** : Water quality index

**IA** : Intelligence Artificielle

**FDI** : Failure Detection and Identification

**PCA** : Principal component analysis

**LDA** : Linear discriminant analysis

**ICA** : Independent component analysis

**CP** : Composante principale

**COV** : La matrice de covariance

**$\sigma^2$**  : Ecart type

***Var*** : La variance

**$\lambda$**  : Les valeurs propres

**V** : Les vecteurs propres

**S<sub>B</sub>** : La variance interclasse

**S<sub>W</sub>** : La variance intra-classe

**J** : L'entropie négative

**CI** : Composant indépendant

**PNN** : Probabilistic neural network

**KNN** : k-nearest neighbor

**NARNET** : Nonlinear autoregressive neural network

**RNN** : Recurrent Neural Network

**LSTM** : Long Short Term Memory

**SVM** : Support Vector Machines

**ELM** : Extreme Learning Machines

**RBF** : Fonction de base radiale

**SLFN** : Single hidden layer feedforward neural network

**Mg** : Magnésium

**B** : Bicarbonate

**H** : Dureté permanente

**FTA** : L'alcaline à titre complet

**ANRH** : L'Agence Nationale des Ressources Hydrauliques

**i.i.d.** : Independence and identical distribution

**CV** : Cross validation

**OOS** : Test hors échantillon

**CV-BI** : Validation croisée bloquée

**ACC** : Accuracy

# LISTE DES FIGURES

<i>Figure</i>	<i>Page</i>
<b>Figure 1.1.</b> Les pourcentages des types d'eau propre.	7
<b>Figure 1.2.</b> Les caractéristiques de l'eau.	8
<b>Figure 1.3.</b> Chaîne de traitement des eaux de surface.	15
<b>Figure 1.4.</b> Classification globale des méthodes de surveillance.	23
<b>Figure 2.1.</b> Système de reconnaissance de formes comprenant la sélection et l'extraction des caractéristiques.	27
<b>Figure 2.2.</b> Réduction de dimensionnalité basée sur l'extraction de caractéristiques.	28
<b>Figure 2.3.</b> Un exemple de la technique PCA.	29
<b>Figure 2.4.</b> Étapes visualisées pour calculer l'espace PCA à l'aide de la méthode de la matrice de covariance.	32
<b>Figure 2.5.</b> Projection des données en PCA.	32
<b>Figure 2.6.</b> Étapes visualisées pour calculer un sous-espace de dimension inférieure de la technique LDA.	39
<b>Figure 2.7.</b> Projection des échantillons originaux sur l'espace de dimension inférieure de LDA.	40
<b>Figure 2.8.</b> Visualisation des étapes de prétraitement dans ICA. (A) l'étape de centrage, (B) L'étape de blanchiment.	43
<b>Figure 2.9.</b> Réduction de dimensionnalité basée sur de la sélection des caractéristiques.	47
<b>Figure 3.1.</b> Architecture RNN standard et structure dépliée avec T pas de temps.	51
<b>Figure 3.2.</b> Architecture LSTM RNN.	54
<b>Figure 3.3.</b> La structure d'un SVM de base.	56
<b>Figure 3.4.</b> Mapper les données d'apprentissage de manière non linéaire dans un espace de caractéristiques de dimension supérieure via $\Phi$ , et construire un hyperplan de séparation avec une marge maximale.	58

<b>Figure 3.5.</b> Architecture de classification selon l'approche un contre tous.	61
<b>Figure 3.6.</b> Architecture de classification selon l'approche un contre un.	62
<b>Figure 3.7.</b> La structure de base de l'ELM.	64
<b>Figure 4.1.</b> Le système de surveillance multi-capteurs de la qualité de l'eau.	67
<b>Figure 4.2.</b> Carte géographique situant le barrage « Tilesdit » [Google Maps].	68
<b>Figure 4.3.</b> Image représentant le site du barrage « Tilesdit » [Google Earth].	69
<b>Figure 4.4.</b> Mesures des paramètres physico-chimiques spécifiques de la qualité des eaux brutes (station Tilesdit).	71
<b>Figure 4.5.</b> Variabilité du z-score des données.	72
<b>Figure 4.6.</b> Données d'origine.	73
<b>Figure 4.7.</b> Extraction de caractéristiques à l'aide du PCA.	73
<b>Figure 4.8.</b> Histogramme des valeurs propres de la composante principale.	74
<b>Figure 4.9.</b> Extraction de caractéristiques à l'aide de LDA.	76
<b>Figure 4.10.</b> Histogramme des valeurs propres des coefficients de la fonction discriminante.	78
<b>Figure 4.11.</b> Visualisation des signaux de mélange des données étudiées dans ce travail lors de l'étape de blanchiment.	80
<b>Figure 4.12.</b> Extraction de caractéristiques à l'aide d'ICA.	81
<b>Figure 4.13.</b> Histogramme des valeurs propres des composants indépendants.	82

# LISTE DES TABLEAUX

<i>Tableau</i>	<i>Page</i>
<b>Tableau 4.1.</b> Statistiques descriptives des paramètres physico-chimiques.	70
<b>Tableau 4.2.</b> Statistiques descriptives des principaux composants créés.	74
<b>Tableau 4.3.</b> Corrélation entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée dans les quatre premiers CP.	75
<b>Tableau 4.4.</b> Statistiques descriptives des coefficients de fonction discriminante créés.	77
<b>Tableau 4.5.</b> Statistiques descriptives des composants indépendants créés.	81
<b>Tableau 4.6.</b> Corrélation entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée dans les trois premiers CI.	83
<b>Tableau 4.7.</b> Classification à l'aide de LSTM RNN monocouches.	87
<b>Tableau 4.8.</b> Classification utilisant des LSTM RNN à deux couches avec la méthode <i>Random-Holdout</i> .	89
<b>Tableau 4.9.</b> Classification utilisant SVM multi-classe.	90
<b>Tableau 4.10.</b> Classification utilisant ELM.	91
<b>Tableau 4.11.</b> Caractéristiques principales des modèles (LDA-LSTM, LDA-SVM et LDA-ELM).	92

# INTRODUCTION GENERALE

L'eau est l'une des éléments clés nécessaires à la survie des êtres vivants. Elle est à l'origine de la vie. La quantité totale de l'eau sur terre reste infiniment constante et stable et que c'est sa répartition qui change. Il convient de souligner que le problème de l'eau n'est pas un problème de quantité mais également de qualité et de débit. L'eau couvre plus de 70 % de la surface de la Terre, mais seulement 1 % de celle-ci est de l'eau brute utilisable [1]. Malgré cette faible quantité d'eau brute, elle souffre cependant de nombreux risques de pollution tels que le ruissellement agricole, la pollution domestique et industrielle, etc. [2]. Aujourd'hui, la dégradation des eaux brutes est l'une des plus grandes menaces environnementales [3, 4], en plus de ses effets négatifs sur la santé humaine et la durabilité de l'eau, car les maladies d'origine hydrique représentent les 10 principales causes de décès dans le monde [2], parmi ces maladies, les plus mortelles sont le paludisme, la diarrhée, les vers intestinaux, la trypanosomose, la bilharziose et la dengue [5-7].

En effet, 663 millions de personnes aujourd'hui n'ont pas accès à l'eau potable [8]. D'ici 2025, les prélèvements d'eau augmenteront de 50 % dans les pays en développement et de 18 % dans les pays développés, ce qui suggère que d'ici là, les deux tiers de la population mondiale vivront dans des zones à fort stress hydrique [8]. Ce prélèvement d'eau se fait majoritairement dans les aquifères souterrains. Nourrir la population croissante sera un grand défi car un tiers de la production alimentaire mondiale se trouve aujourd'hui dans les zones de stress hydrique élevé. La pénurie d'eau affecte toutes les sphères de la vie humaine. Un tiers des écoles dans le monde n'ont pas accès à l'eau potable et à l'assainissement, et le même nombre d'hôpitaux dans les pays en développement sont privés d'eau potable pour la santé et l'assainissement. Ce problème d'eau est en grande partie dû à l'existence de ressources en eau brute très limitées et très inégalement réparties. L'augmentation de la demande en eau d'une population sans cesse croissante et la pollution continue de l'eau par les activités humaines ne font qu'aggraver la pénurie d'eau à travers le monde. De plus, un enfant meurt toutes les 90 secondes des suites d'une maladie liée à l'eau [9, 10].

L'eau présente dans la nature n'est pas potable directement car elle contient des solides en suspension, des micro-organismes, des sels dissous (ions) et des gaz dissous qui peuvent être nocifs pour le corps humain [8]. Par conséquent, pour consommer de l'eau en toute sécurité, il faut la traiter. Cependant, la pollution croissante des réserves d'eau complique le processus de traitement et le rend plus sensible, obligeant les transformateurs d'eau à constamment innover et développer de nouvelles technologies. Les technologies de traitement de l'eau a connu un grand développement ces dernières années [11]. L'assurance de la qualité de l'eau dépend de la surveillance permanente et continue des services associés au traitement et à la distribution.

En général, le traitement de l'eau a pour objectif de fournir une quantité d'eau adéquate pour répondre aux besoins nécessaires et assurer sa haute qualité [12]. Cela nécessite une surveillance continue de toutes les étapes du processus de traitement grâce à des mesures quantitatives et qualitatives de sa qualité. La plupart des pays en développement s'appuient encore sur des méthodes traditionnelles de contrôle de la qualité de l'eau dans la plupart des usines d'approvisionnement en eau potable. Les méthodes traditionnelles reposent sur la compréhension des différents paramètres descripteurs de qualité de l'eau propre à travers de différentes analyses physico-chimiques réalisées en laboratoire, afin de déterminer ultérieurement son état et de trouver les moyens adaptés pour le traitement de potabilité de l'eau. L'inconvénient de cette méthode est de nécessiter l'intervention d'un expert humain avec un temps long pour déterminer l'état de la qualité des eaux [13]. De plus, elle ne permet pas de suivre l'évolution de la qualité de l'eau en temps réel. Ainsi, l'automatisation de ces procédés joue un rôle important dans la réduction des contraintes de coûts d'exploitation et le contrôle efficace de la qualité de l'eau en temps réel.

Récemment, les méthodes d'automatisation dans le domaine du contrôle de la qualité de l'eau ont été considérablement développées. En général, ces méthodes se répartissent en deux grandes catégories [14]: La première catégorie est celle basée sur l'existence d'un modèle formel. L'inconvénient de cette classe est qu'il existe des incertitudes dans le modèle qui ne peuvent pas prendre en compte tous les paramètres nécessaire de surveillance. La deuxième catégorie est celle qui repose sur les connaissances préalables d'un opérateur humain et sur l'analyse des variables. Cette catégorie peut également être divisée en deux classes : la première catégorie comprend des outils de prétraitement de données, notamment des techniques d'extraction de

caractéristiques telles que l'analyse en composantes principales (ou principal component analysis (PCA)), l'analyse discriminante linéaire (ou linear discriminant analysis (LDA)), et l'analyse en composantes indépendantes (ou independent component analysis (ICA)) [15-17], également appelés outils de traitement de bas niveau qui permet d'identifier et d'éliminer les variables qui pénalisent les performances d'un modèle complexe dans la mesure où elles peuvent être bruitées, redondantes ou non pertinentes et de passer outre le fléau de la haute dimensionnalité de ces données; et la deuxième classe est plus orientée vers la communication avec un expert [18], également appelés outils de haut niveau, représentés en techniques de l'intelligence artificielle (IA). L'avantage des techniques d'IA est que leur réponse est plus détaillée et est-elle obtenue à partir de données brutes pour les variables de contrôle, ou à partir de données traitées pour les sorties de traitement de bas niveau [14]. Cependant, les performances des techniques d'IA utilisant les données de prétraitement générées par la sortie d'outils de traitement de bas niveau sont souvent meilleures [19].

Construire des modèles précis et fiables basés sur des techniques d'IA ou des techniques d'apprentissage automatique est l'une des solutions efficaces pour surveiller la qualité de l'eau en temps réel et à faible coût. Ces dernières années, l'application des techniques de classification et de régression à apprentissage automatique a suscité un grand intérêt dans le domaine de la surveillance de la qualité de l'eau [20, 21]. Par exemple : Dezfouli et al. [22] ont présenté une étude comparative de trois techniques d'apprentissage automatique, réseau de neurone probabiliste (probabilistic neural network (PNN)), machine à vecteurs de support (support vector machine (SVM)) et k-plus proche voisin (k-nearest neighbor (KNN)) pour classer la qualité de l'eau. Les résultats de leur étude ont montré que PNN donne les meilleures performances avec une précision de classification de 90.70 %. Aldhyani et al. [23] ont utilisé plusieurs techniques d'apprentissage automatique pour prédire l'indice de qualité de l'eau (water quality index (WQI)) et la classification de la qualité de l'eau. Les résultats ont révélé que le modèle de réseau de neurone autorégressif non linéaire (nonlinear autoregressive neural network (NARNET)) fonctionnait légèrement mieux que les réseau de neurones récurrents long short term memory (long short term memory recurrent neural networks (LSTM RNNs)) pour prédire le WQI. Alors que le modèle SVM a une efficacité élevée dans la classification de la qualité de l'eau, avec une précision de 97,01 %. Gakii et Jepkoech [24] ont étudié les performances de quatre types d'algorithmes d'arbre de décision qui incluent J48, LMT, Random Forest et Random tree. Leurs

résultats indiquent que la technique d'arbre de décision J48 a donné les meilleures performances avec une précision de classification de 94%. Djerioui et al., [12] ont proposé un capteur logiciel de chlore pour la surveillance de la qualité de l'eau dans une étude comparative entre les machines d'apprentissage extrême (Extreme Learning Machines (ELM)) et SVM. Les résultats de leur étude ont montré que l'algorithme ELM a une grande efficacité pour prédire la concentration de chlore et une efficacité élevée dans la classification de la qualité de l'eau de deux techniques ELM et SVM, avec une précision de 99,30 %. Le problème de surveillance de la qualité de l'eau peut être considéré comme un problème de reconnaissance de formes, où les classes correspondent aux différents états qualitatifs de l'eau, et les formes représentent l'ensemble des caractéristiques physico-chimiques de l'eau à surveiller. La technique appropriée est sélectionnée en fonction de sa capacité d'apprentissage et de généralisation et de sa capacité à prendre en compte la nature dynamique et complexe du processus [25].

Le travail présenté dans cette thèse vise à étudier et implémenter des modèles basés sur l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) qui consiste à construire d'un ensemble pertinent et réduit de nouvelles variables à partir de l'ensemble de variables originales, avec des techniques d'apprentissage automatique (LSTM RNNs, SVM, et ELM) appliquées à la classification de la qualité de l'eau. Ces modèles sont étudiés à l'aide d'une base de données réelle de différents paramètres physico-chimiques collectés à la station du barrage de Tilesdit dans la wilaya de Bouira (Algérie). Une étude comparative en simulation portant sur l'amélioration de décision en termes d'évaluation et de validation les performances de chacune de ces modèles hybrides est effectuée, dans un but d'un choix décisif adapté au problème de surveillance de la qualité des eaux propres.

Ce travail est organisé en quatre chapitres qui sont présentent comme suit :

Dans le premier chapitre, des généralités sont présentées sur l'eau propre. Une description générale de cette ressource naturelle et ses diverses propriétés est décrite. La chaîne habituelle de production et de traitement d'eau brute est également présentée, en plus de diverses méthodes de surveillance de la qualité de l'eau.

Dans le deuxième chapitre, le problème d'avoir un grand nombre de dimensions et son impact sur l'apprentissage automatique est abordé. Diverses méthodes pour réduire les dimensions pour la construction des modèles sont également présentées. Dans ce contexte, les

méthodes les plus fréquemment utilisées pour l'extraction de caractéristiques (PCA, LDA et ICA) et la sélection de caractéristiques (le coefficient de corrélation entre les variables) appliquées aux systèmes de surveillance sont présentées.

Dans le troisième chapitre, les méthodes d'apprentissage automatique supervisé les plus importantes appliquées aux problèmes de classification sont présentées. Le concept de réseaux de neurones récurrents (RNNs) est rappelé et sa structure et ses caractéristiques générales sont décrites. La syntaxe générale de la technique SVM appliquée à la classification est également décrite. Enfin, un bref sur la méthode machine d'apprentissage extrême (ELM) est également présenté.

Le quatrième chapitre est dédié à la simulation et l'évaluation des techniques de l'intelligence artificielle proposées pour l'amélioration de décision et de diagnostic des systèmes de surveillance automatique de la qualité de l'eau. La validation et l'évaluation des performances de chacune des techniques proposées dans une étude comparative représente l'objectif majeur de notre travail. La problématique de l'étude ainsi que le système de surveillance proposé sont présentés. Une brève description de la zone d'étude ainsi que la base de données utilisée est présentée. Dans ce contexte, les résultats de l'extraction et de la sélection de caractéristiques à l'aide des techniques choisies : PCA, LDA, et ICA sont présentés et discutés. Une explication détaillée du processus d'apprentissage et de classification utilisant les techniques LSTM RNNs, SVM et ELM est également donnée. Une discussion des résultats de réduction dimensionnelle et de classification conclura ce travail de simulation pour choisir le modèle hybride le mieux adaptée à l'application proposée.

Enfin, une conclusion générale de cette thèse est envisagée qui évoque les différentes étapes appliquées et souligne les perspectives d'avenir prévues.

## *Chapitre I*

# **SURVEILLANCE DES PROCESSUS DE PRODUCTION D'EAU POTABLE**

### **Introduction**

L'eau potable consommée par l'homme doit être pure, claire et exempte de micro-organismes et de produits chimiques nocifs, et l'eau des réseaux d'eau doit avoir un niveau élevé de propreté et de pureté [26]. L'eau distribuée à travers le réseau représente l'un des produits alimentaires essentiels les plus contrôlés et ses analyses sont effectuées de la source au robinet. L'objectif principal des usines de production et de traitement d'eau est de suivre les différents paramètres descripteurs de l'eau propre (paramètres physico-chimiques et microbiologiques) pour déterminer son état, puis de rechercher des méthodes appropriées pour la rendre potable. Par conséquent, la surveillance permanente de la qualité de l'eau est nécessaire, et elle est effectuée par des données qualifiables et quantifiables ainsi que de contrôler le bon fonctionnement des différents procédés de traitement, afin d'atteindre une qualité élevée et uniforme de façon automatique, tout en ne ralentissant pas la production [27].


Dans ce chapitre, des généralités sont données sur l'eau propre. Dans un premier temps, l'eau propre et ses différentes caractéristiques sont définies. Ensuite, la chaîne habituelle de production et de traitement de l'eau propre, ainsi que les différentes méthodes de surveillance industrielle, sont présentées.

### **1. Définition de l'eau potable**

L'eau potable est une source alimentaire qui peut être consommée sans causer de problèmes de santé et qui se caractérise par sa propreté et est exempte de substances nocives et de microbes. Les gouvernements fixent des normes pour l'eau fournie au public pour être utilisée pour boire, se baigner et se laver [28].

## 1.1.Types des eaux propres

Il existe trois types d'eau propre qui sont: l'eau minérale naturelle, l'eau de source et l'eau traitée. La figure 1.1 montre le pourcentage de chaque type.



**Figure 1.1.** Les pourcentages des types d'eau propre.

### 1.1.1. L'eau minérale naturelle

L'eau minérale naturelle est définie comme une eau qui est :

- Obtenu directement à partir de sources souterraines protégées des risques de pollution.
- Caractérisé par sa teneur en certains sels minéraux et leurs proportions relatives.
- Garantit la constance de sa composition et la stabilité de son flux collecté dans des conditions qui garantissent la pureté microbiologique et la composition chimique d'origine.
- Ne peut être soumis à aucun traitement (sauf pour des traitements limités tels que la carbonatation, l'élimination du fer ou du manganèse).

### 1.1.2. L'eau de source

Les eaux de source sont des eaux qui :

- Proviennent d'une source souterraine ou de surface spécifique.
- N'ont pas traversé un réseau d'eau communautaire.

- Sont protégés dans des périmètres de vulnérabilité définis pour éviter la pollution et la contamination.
- Sont toujours propres à la consommation humaine à la source et conservés dans cet état jusqu'à l'utilisation.

### 1.1.3. L'eau traitée

L'eau traitée peut :

- Proviennent de tout type d'approvisionnement en eau.
- Être soumis à tout traitement modifiant l'eau d'origine afin de se conformer aux exigences de sécurité chimique, microbiologique et radiologique pour l'eau consommée.

## 2. Caractéristiques de l'eau

La qualité de l'eau est déterminée par ses caractéristiques. Les caractéristiques de l'eau peuvent être classées en trois grandes catégories: physiques, chimiques et biologiques (figure 1.2). Ces propriétés de qualité de l'eau à travers le monde sont caractérisées par une grande variabilité. Par conséquent, la qualité des sources d'eau utilisées à des fins différentes devrait être établie en fonction des paramètres de qualité de l'eau spécifiques qui affectent le plus l'utilisation possible de l'eau [29]. Dans cette section, un aperçu des caractéristiques de la qualité de l'eau - caractéristiques physiques, chimiques et biologiques est présenté.

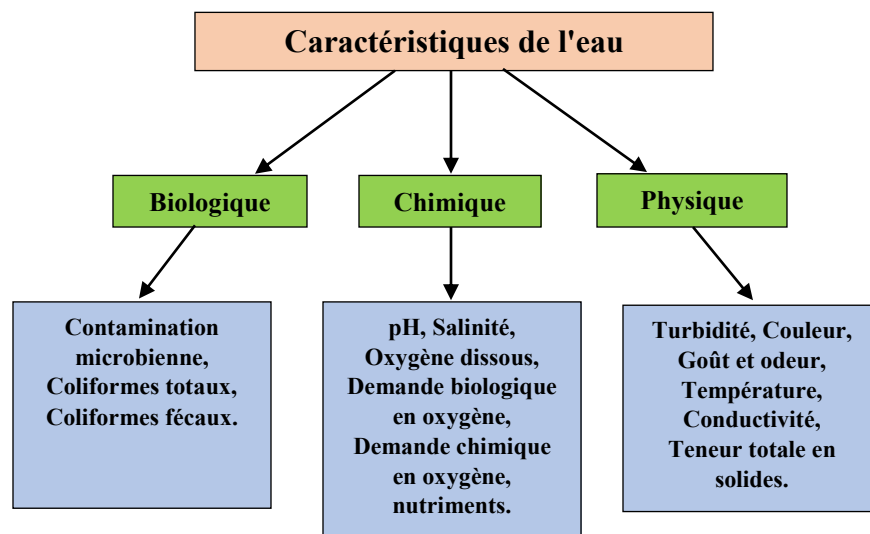


Figure 1.2. Les caractéristiques de l'eau.

## **2.1. Caractéristiques physiques de l'eau**

### **2.1.1. Turbidité**

La turbidité (TU) est une mesure des propriétés de transmission de la lumière de l'eau et se compose de matières en suspension et colloïdales. C'est important pour des raisons de santé et d'esthétique. La turbidité est mesurée par une tige de turbidité ou par un turbidimètre avec observations optiques et est exprimée en quantité de matières en suspension en mg/l ou partie par million (ppm) [30].

### **2.1.2. Couleur**

La couleur dans l'eau est avant tout une préoccupation de qualité de l'eau pour des raisons esthétiques. L'eau colorée donne l'impression d'être impropre à la consommation, même si l'eau peut être parfaitement sûre pour un usage public. D'autre part, la couleur peut indiquer la présence de substances organiques, telles que des algues ou des composés humiques. Plus récemment, la couleur a été utilisée comme une évaluation quantitative de la présence de matières organiques potentiellement dangereuses ou toxiques dans l'eau. L'unité de couleur standard est celle qui est produite par un milligramme de platine cobalt dissous dans un litre d'eau distillée [30].

### **2.1.3. Goût et odeur**

Le goût et l'odeur sont les perceptions humaines de la qualité de l'eau. La perception humaine du goût comprend l'acide (acide chlorhydrique), le salé (chlorure de sodium), le sucré (saccharose) et l'amer (caféine). Des composés relativement simples produisent des goûts aigres et salés. Cependant, les goûts sucrés et amers sont produits par des composés organiques plus complexes. Les matières organiques rejetées directement dans l'eau, telles que la chute des feuilles, le ruissellement, etc., sont des sources de goûts et de composés odorants libérés lors de la biodégradation [30].

### **2.1.4. Température**

La température de l'eau affecte certaines des propriétés physiques et caractéristiques importantes de l'eau: capacité thermique, densité, poids spécifique, viscosité, tension superficielle, conductivité spécifique, salinité et solubilité des gaz dissous, etc. Les taux de

réaction chimique et biologique augmentent avec l'augmentation de la température. Les taux de réaction sont généralement supposés doubler pour une augmentation de la température de 10 °C. La température de l'eau des ruisseaux et rivières du monde entier varie de 0 à 35 °C [29].

### **2.1.5. Conductivité**

La concentration de solides dissous totaux (SDT) est liée à la conductivité électrique (CE;  $\mu\text{S}/\text{cm}$ ) ou à la conductance spécifique. La conductivité mesure la capacité de l'eau à transmettre le courant électrique. La conductivité est un terme relatif et la relation entre la concentration de SDT et la conductivité est unique à un échantillon d'eau donné et dans une plage de concentration de SDT spécifique. La conductivité augmente à mesure que la concentration de SDT augmente [29].

### **2.1.6. Teneur totale en solides**

La teneur totale en solides de l'eau est définie comme le résidu restant après évaporation de l'eau et séchage du résidu jusqu'à un poids constant de 103 °C à 105 °C. La fraction organique (ou teneur en solides volatils) est considérée comme étant liée à la perte de poids du résidu restant après évaporation de l'eau et après inflammation du résidu à une température de 500 °C. Les solides volatils s'oxyderont à cette température et seront chassés sous forme de gaz. Les solides sont classés comme solides décantables, solides en suspension et solides filtrables. Les solides en suspension et les solides filtrables sont classés en fonction de la taille des particules et de la rétention des solides en suspension sur les filtres en fibre de verre standard [31].

## **2.2. Caractéristiques chimiques de l'eau**

### **2.2.1. pH**

Le pH est une abréviation représentant l'activité ou la concentration des ions hydrogène dans une solution. Il décrit l'état acide ou basique (également appelé alcalin) des liquides sur une échelle allant de 0 à 14. Les liquides ayant un pH de 7,0, comme l'eau distillée, sont neutres, ni acides ni basiques. Les liquides dont le pH est inférieur à 7,0 sont acides. Les substances fortement acides sont appelées acides. Les liquides dont le pH est supérieur à 7,0 sont basiques. Les substances fortement basiques sont appelées bases [32].

### **2.2.2. Salinité**

La salinité est une mesure de la quantité de sels dans l'eau. Parce que les ions dissous augmentent la salinité ainsi que la conductivité, les deux mesures sont liées. Les sels et autres substances affectent la qualité de l'eau utilisée pour l'irrigation ou la boisson. La présence d'une teneur élevée en sel peut rendre l'eau impropre à un usage domestique, agricole ou industriel [33].

### **2.2.3. Oxygène dissous (DO)**

L'oxygène dissous est important dans l'eau naturelle car de nombreux micro-organismes en ont besoin dans le système aquatique. L'oxygène dissous établit également un environnement aérobie dans lequel les formes oxydées de nombreux constituants de l'eau sont prédominantes. Dans des conditions anoxiques dans l'eau, des formes réduites d'espèces chimiques se forment et conduisent fréquemment à la libération d'odeurs indésirables jusqu'à ce que des conditions oxygénées se développent [29].

### **2.2.4. La demande biologique en oxygène (DBO)**

La demande biologique en oxygène (DBO), le paramètre le plus largement utilisé, est une mesure de la quantité d'oxygène utilisée par la population microbienne indigène dans l'eau en réponse à l'introduction de matière organique dégradable. Ce paramètre dépend des caractéristiques de l'eau: dilution, nutriments essentiels (N, P, K, Fe, etc.) et semences de bactéries. La DBO sur 5 jours ( $DBO_5$ ) est la plus utilisée. La  $DBO_5$  de l'eau naturelle est liée à la concentration en oxygène dissous, qui est mesurée à temps zéro et après 5 jours d'incubation à 20 °C. La différence est l'oxygène dissous utilisé par les micro-organismes dans l'oxydation biochimique de la matière organique. Les concentrations typiques de  $DBO_5$  pour les ruisseaux et les rivières du monde entier sont < 2 à 15 mg/L et la plage observée est < 2 à 65 mg/L [29].

### **2.2.5. La demande chimique en oxygène (DCO)**

Le test de la demande chimique en oxygène (DCO) de l'eau naturelle donne l'équivalent en oxygène de la matière organique qui peut être oxydée par un agent oxydant chimique puissant en milieu acide. La DCO observée dans les ruisseaux et rivières naturels est de < 2 mg/L à 100 mg/L [29].

## 2.2.6. Les nutriments

### 2.2.6.1. Composés azotés

L'azote est essentiel pour les organismes vivants en tant que constituant important des protéines, y compris du matériel génétique. Les plantes et les micro-organismes transforment l'azote inorganique en formes organiques. Dans l'environnement, l'azote inorganique se trouve dans une gamme d'états d'oxydation tels que le nitrate ( $\text{NO}_3^-$ ) et le nitrite ( $\text{NO}_2^-$ ), l'ion ammonium ( $\text{NH}_4^+$ ) et l'azote moléculaire ( $\text{N}_2$ ). Il subit des transformations biologiques et non biologiques dans l'environnement dans le cadre du cycle de l'azote [34].

**Ammoniac :** L'ammoniac est naturellement présent dans les plans d'eau en raison de la dégradation des matières organiques et inorganiques azotées dans le sol et l'eau, l'excrétion par le biote, la réduction de l'azote gazeux dans l'eau par les micro-organismes et les échanges gazeux avec l'atmosphère. Il est également déchargé dans les plans d'eau par certains procédés industriels (par exemple la production de pâte et de papier à base d'ammoniaque) et également en tant que composant des déchets municipaux ou communautaires. À certains niveaux de pH, des concentrations élevées d'ammoniac ( $\text{NH}_3$ ) sont toxiques pour la vie aquatique et, par conséquent, préjudiciable à l'équilibre écologique des plans d'eau [34].

**Nitrate et nitrite :** L'ion nitrate ( $\text{NO}_3^-$ ) est la forme courante d'azote combiné que l'on trouve dans les eaux naturelles. Il peut être réduit biochimiquement en nitrite ( $\text{NO}_2^-$ ) par des processus de dénitrification, généralement dans des conditions anaérobies. L'ion nitrite est rapidement oxydé en nitrate. Les sources naturelles de nitrate dans les eaux de surface comprennent les roches ignées, le drainage des terres et les débris végétaux et animaux [34].

**Azote organique :** L'azote organique se compose principalement de substances protéiques (par exemple, les acides aminés, les acides nucléiques et l'urine) et le produit de leurs transformations biochimiques (par exemple les acides humiques et les acides fulviques). L'azote organique est naturellement soumis aux fluctuations saisonnières de la communauté biologique car il est principalement formé dans l'eau par le phytoplancton et les bactéries, et cyclé dans la chaîne alimentaire. Des concentrations accrues d'azote organique pourraient indiquer la pollution d'une masse d'eau [34].

### **2.2.6.2. Composés du phosphore**

Le phosphore est un nutriment essentiel pour les organismes vivants et existe dans les plans d'eau en tant qu'espèces dissoutes et particulaires. C'est généralement le nutriment limitant pour la croissance des algues et par conséquent, contrôle la productivité primaire d'un plan d'eau. Dans les eaux naturelles, le phosphore se présente principalement sous forme d'orthophosphates et de polyphosphates dissous et de phosphates liés organiquement. Les changements entre ces formes se produisent en continu en raison de la décomposition et de la synthèse des formes organiquement liées et des formes inorganiques oxydées [34].

## **2.3. Caractéristiques biologiques**

### **2.3.1. Contamination microbienne**

La contamination microbienne des milieux aquatiques est l'un des enjeux cruciaux au regard de l'état sanitaire des plans d'eau utilisés pour l'approvisionnement en eau potable, les activités récréatives et la récolte des fruits de mer en raison d'une contamination potentielle par des bactéries pathogènes, des protozoaires ou des virus [33].

### **2.3.2. Coliformes totaux et coliformes fécaux**

Les bactéries coliformes totales, les bactéries coliformes fécales et *E. coli* sont tous considérés comme des indicateurs de l'eau contaminée par des matières fécales. L'eau contaminée peut contenir d'autres agents pathogènes (micro-organismes responsables de maladies) qui sont plus difficiles à rechercher. Par conséquent, ces bactéries indicatrices sont utiles pour nous donner une mesure des niveaux de contamination [33].

## **3. Le traitement de l'eau**

Le traitement de l'eau est tout processus qui améliore la qualité de l'eau pour la rendre appropriée à une utilisation finale spécifique. L'utilisation finale peut être la boisson, l'approvisionnement en eau industrielle, l'irrigation, l'entretien du débit des rivières, les loisirs aquatiques ou de nombreuses autres utilisations, y compris le retour dans l'environnement en toute sécurité. Le traitement de l'eau élimine les contaminants et les composants indésirables, ou réduit leur concentration de sorte que l'eau devienne propre à son utilisation finale souhaitée [14].

L'importance du traitement de l'eau réside dans les points suivants :

- Il est important de protéger la santé : les produits chimiques nocifs, les métaux et autres contaminants présents dans l'eau sont dangereux pour la santé des humains et d'autres organismes. Ces substances et toxines nocives entraînent divers problèmes de santé comme l'asthme, le choléra, la diarrhée, le cancer, des troubles cutanés et même la mort. Par conséquent, cela réduira le taux de mortalité annuel des personnes causées par la consommation d'eau contaminée [28].
- Il aide à restaurer l'eau : avec ce processus, l'eau est réintroduite dans le cycle de la nature.
- Pour protéger l'environnement : le traitement de l'eau est très utile pour l'environnement. Il aide à équilibrer le cycle de l'eau en maintenant les eaux souterraines et de surface.
- L'eau purifiée dans les usines de traitement peut être utilisée à des fins diverses telles que la buvant, l'utilisation domestique, l'application industrielle, l'agriculture et l'irrigation, etc. Cela résoudra le problème de la pénurie d'eau et les pays ayant un accès limité bénéficieront d'une eau potable salubre [28].
- Les stations d'épuration de l'eau sont également importantes car elles répondent à la demande croissante en eau.

### **3.1. Chaîne de traitement**

Les sources d'eau potable sont sujettes à la contamination et nécessitent un traitement approprié pour éliminer les agents pathogènes. Les réseaux publics d'eau potable utilisent diverses méthodes de traitement de l'eau pour fournir de l'eau potable salubre à leurs communautés. Le processus de traitement de l'eau utilisé par les systèmes d'eau communautaires (principalement le traitement des eaux de surface) se décline en cinq étapes fondamentales (figure 1.3) [13]:

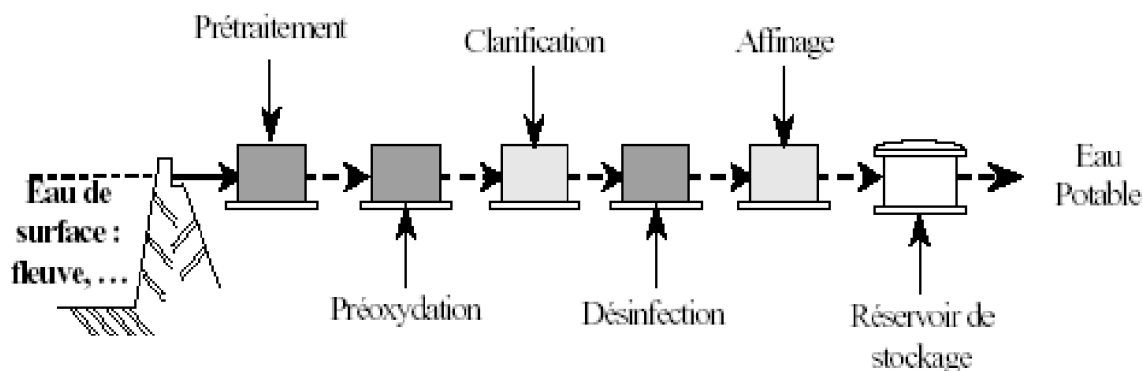


Figure 1.3. Chaîne de traitement des eaux de surface.

### 3.1.1. Prétraitement

Les procédés de prétraitement généralement utilisés par les usines de purification d'eau comprennent: le stockage, le criblage, le préconditionnement et la sédimentation. Une brève description de chaque processus est fournie ci-dessous [35] :

**Stockage** : l'eau de surface peut être stockée dans des réservoirs pendant des jours, des semaines, voire des mois pour profiter du processus de purification naturel.

**Criblage** : il s'agit généralement de la première étape dans les usines de purification d'eau, en particulier pour les usines qui traitent les eaux de surface. Les tamis sont utilisés pour éliminer les gros débris qui pourraient avoir un impact négatif sur le processus et l'équipement de purification de l'eau restants.

**Préconditionnement** : dans cette étape, l'eau est traitée en fonction de ses caractéristiques entrantes. Par exemple, si l'eau entrante est acide, de la chaux est souvent ajoutée pour augmenter le pH. L'eau riche en dureté est souvent traitée avec du carbonate de sodium pour précipiter le carbonate de calcium.

**Sédimentation** : l'eau est généralement retenue dans les bassins de sédimentation pendant au moins 4 heures, ce qui permet aux particules de se déposer.

Les progrès dans le domaine du prétraitement sont généralement axés sur la réduction des coûts globaux, de la taille ou de l'empreinte, et de l'utilisation des produits chimiques connexes, tout en produisant une meilleure qualité initiale de l'eau qui prolonge la durée de vie des

technologies de processus de filtration en aval. En général, les progrès technologiques dans ce domaine ont tendance à se situer dans les personnalisations et / ou adaptations spécifiques au site des technologies établies.

### 3.1.2. Pré-oxydation

La pré-oxydation est utilisée pour améliorer l'élimination de certaines substances chimiques pendant le traitement ou pour réduire les croissances biologiques dans l'usine de traitement. Les oxydants utilisés comprennent: le chlore, le dioxyde de chlore, l'ozone et le permanganate de potassium [36]. Les oxydants sont utilisés pour :

- Contrôler de la croissance biologique dans la station de traitement.
- Contrôler les goûts et les odeurs.
- Oxyder l'arsenic pour permettre son élimination par coagulation.
- Oxyder la matière organique de l'eau pour améliorer le processus de coagulation / floculation.

#### 3.1.2.1. Pré-oxydation au chlore


En présence de matière organique, la pré-chloration s'accompagnera de la formation de composés indésirables; il est donc préférable de placer le point de chloration aussi loin que possible de la ligne de traitement, idéalement en suivant l'élimination maximale possible des précurseurs organiques présents dans l'eau. La pré-chloration ne peut être maintenue que lorsque l'eau ne contient pas de précurseurs en grande quantité; la pré-chloration est utilisée lorsqu'il existe un risque de développement d'algues dans les structures de clarification, ou pour l'élimination des ions  $\text{NH}_4^+$  [37].

#### 3.1.2.2. Pré-oxydation au dioxyde de chlore

Cette technique a été développée pour tenter de remplacer le chlore pendant la pré-oxydation. En effet, le dioxyde de chlore, bien qu'il n'oxyde pas l'ammonium, n'entraînera pas non plus la formation de trihalométhanés. Cependant, lorsqu'il réagit avec la matière organique naturelle, il libère des ions  $\text{ClO}_2^-$  (chlorite) qui doivent ensuite être éliminés [37].

### 3.1.2.3. Pré-oxydation au permanganate de potassium

Cet oxydant est principalement utilisé pour le traitement des eaux brutes contenant du manganèse, qu'il précipite selon la réaction suivante [37]:



Cette réaction est favorisée par un pH élevé, accélérant la cinétique de réaction, d'où la nécessité de contrôler le pH (> 7,0) et de prévoir un temps de contact suffisant (5-10 minutes).

Dans le cas d'eaux à faible teneur minéralisée, contenant des niveaux élevés de matière organique dissoute et nécessitant un pH de coagulation très bas (5,5 à 6), la préférence doit être donnée à la localisation du point d'injection de  $KMnO_4$  entre le décanteur et le filtre après avoir ajusté le pH à un niveau favorable (7,0 à 7,5).

Le permanganate de potassium est également parfois utilisé pour l'oxydation partielle de certaines matières organiques, pour éliminer les goûts désagréables ou pour lutter contre le développement d'algues au sein des équipements de clarification.

L'utilisation de  $KMnO_4$  pour la pré-oxydation nécessite que la quantité injectée soit méticuleusement contrôlée; car tout excès de dosage peut conférer une coloration rose à l'eau traitée, causée par la présence de Mn soluble.

### 3.1.2.4. Pré-oxydation à l'ozone

Lorsqu'il est utilisé pour le prétraitement des eaux de surface brutes, l'ozone, comme le  $ClO_2$ , empêche la formation de trihalométhane et d'autres dérivés chlorés. Il n'oxyde pas l'ammonium mais crée des conditions qui favorisent la nitrification ultérieure. Bien que l'ozone soit moins efficace que le chlore dans cette application, c'est en fait le pré-oxydant le plus largement utilisé dans les systèmes de clarification car il a un certain nombre d'effets bénéfiques [37]:

- ✓ Améliore l'efficacité de la clarification (turbidité, couleur, micro-algues résiduelles, matière organique et précurseurs de trihalométhane... etc.);
- ✓ Dans certains cas, réduit la demande de coagulant;
- ✓ Préparer l'eau pour un traitement biologique ultérieur.

Si un événement lié à la pré-oxydation se produit (c'est-à-dire que la qualité de l'eau est affectée par le processus de pré-oxydation), ce qui suit peut arriver :

- Si trop peu d'oxydant est ajouté à l'eau, la maladie peut survenir en raison de la mauvaise performance du processus de coagulation et de la mauvaise élimination des germes et des produits chimiques, tels que l'arsenic, et des toxines contenues dans les algues ou les cyanobactéries.
- Si trop d'oxydant est ajouté à l'eau, les oxydants eux-mêmes, les sous-produits de désinfection ou les toxines libérées par les algues ou les cyanobactéries, lorsqu'ils sont tués peuvent causer des maladies.
- Des concentrations élevées de sous-produits de désinfection ou de toxines libérées par les algues ou les cyanobactéries, lorsqu'elles sont tuées, peuvent provoquer des maladies, même lorsque la dose d'oxydant est acceptable.

### **3.1.3. Clarification**

Les matières en suspension dans les approvisionnements en eau brute sont éliminées par diverses méthodes pour fournir une eau adaptée à des fins domestiques et à la plupart des besoins industriels. La matière en suspension peut être constituée de gros solides, qui peuvent se déposer par gravité seule sans aucune aide extérieure, et de matériaux non sédimentables, souvent de nature colloïdale. L'élimination est généralement réalisée par coagulation et floculation. La combinaison de ces processus est appelée clarification conventionnelle [38].

#### **3.1.3.1. Étapes de clarification**

Les particules finement divisées en suspension dans l'eau de surface se repoussent car la plupart des surfaces sont chargées négativement. Les étapes de clarification suivantes sont nécessaires pour l'agglomération des particules :

Coagulation : La coagulation peut être réalisée par l'addition de sels inorganiques d'aluminium ou de fer. Ces sels inorganiques neutralisent la charge sur les particules provoquant la turbidité de l'eau brute, et s'hydrolysent également pour former des précipités insolubles, qui emprisonnent les particules. La coagulation peut également être effectuée par l'addition de polymères organiques solubles dans l'eau avec de nombreux sites ionisés pour la neutralisation de la charge des particules.

Floculation : La floculation, l'agglomération de particules déstabilisées en grosses particules, peut être améliorée par l'addition de polymères organiques hydrosolubles de haut poids moléculaire. Ces polymères augmentent la taille des floes par liaison au site chargé et par pontage moléculaire.

#### **3.1.4. Désinfection**

La désinfection de l'eau signifie l'élimination, la désactivation ou la mise à mort des micro-organismes pathogènes. Les micro-organismes sont détruits ou désactivés, ce qui entraîne l'arrêt de la croissance et de la reproduction. L'eau peut être désinfectée par des désinfectants physiques ou chimiques. Les agents éliminent également les contaminants organiques de l'eau, qui servent de nutriments ou d'abris pour les micro-organismes. Les désinfectants ne doivent pas seulement tuer les micro-organismes. Les désinfectants doivent également avoir un effet résiduel, ce qui signifie qu'ils restent actifs dans l'eau après la désinfection. Un désinfectant doit empêcher les microorganismes pathogènes de se développer dans la plomberie après la désinfection, provoquant la recontamination de l'eau.

Pour la désinfection chimique de l'eau, les désinfectants suivants peuvent être utilisés: chlore ( $\text{Cl}_2$ ), dioxyde de chlore ( $\text{ClO}_2$ ) et ozone ( $\text{O}_3$ ).

Pour la désinfection physique de l'eau, les désinfectants suivants peuvent être utilisés: lumière ultraviolette (UV), rayonnement électronique et rayons gamma.

Les facteurs critiques qui affectent l'efficacité de la désinfection sont les suivants [39]:

- Nature du désinfectant
- Concentration du désinfectant
- Durée de contact entre le désinfectant et le microbe
- Température
- Type et concentration d'organismes
- pH et force ionique

Pour chaque type de traitement, les paramètres physico-chimiques suivants doivent être contrôlés [13]:

- La température : l'augmentation de la température conduit à une accélération de la prolifération microbiologique. Par conséquent, la température doit être surveillée et d'ajuster les consignes du désinfectant en conséquence.
- Le pH : la variation du pH affecte l'efficacité du chlore présent dans l'eau. Par conséquent, ce paramètre doit être surveillé en même temps que le chlore libre.
- La turbidité : elle caractérise la présence des particules dans l'eau. La présence de turbidité est le signe d'un traitement incomplet. Les particules non retenues lors du traitement peuvent « véhiculer » des microorganismes qui seront plus difficiles à inactiver par les désinfectants. Enfin, la turbidité révèle la présence de matières en suspension qui pourront former des dépôts dans le réseau, lesquels favorisent, à l'abri de l'action des désinfectants, la prolifération microbienne.
- $\text{NH}_4^+$  et  $\text{NO}_2^-$  : ils sont consommés par le  $\text{Cl}_2$  et peuvent être considérés comme des indicateurs de pollution.

Ces contrôles sont souvent effectués en entrée ou en sortie des connecteurs de désinfection.

### 3.1.5. Affinage

Le but du raffinage est de dégrader la matière organique et d'éliminer les micropolluants. De plus, il améliore les qualités organoleptiques de l'eau telles que l'odeur, la saveur et la limpidité [28].

***L'affinage par charbons actifs*** : La filtration au charbon est une méthode de filtration dans laquelle un morceau de charbon actif est utilisé pour éliminer les contaminants et les impuretés, en utilisant l'absorption chimique. Chaque morceau de carbone est conçu pour fournir une grande partie de la surface, afin de permettre à la plus grande quantité possible de contaminants d'être exposée au moyen filtrant. Une livre (454 g) de charbon actif contient environ 100 acres (1 km<sup>2</sup> / kg). Ce carbone s'active avec une charge positive et est conçu pour attirer les polluants de l'eau chargés négativement.

Les filtres à charbon sont les plus efficaces pour éliminer le chlore, les sédiments et les composés organiques volatils de l'eau. Cependant, il n'est pas efficace pour éliminer les minéraux, les sels et les composés inorganiques dissous.

**L'affinage par stripping :** Pour extraire les gaz dissous dans l'eau, on applique un contre-courant de gaz d'entraînement. Le stripping retient principalement les composés volatils (benzène, trihalométhane, composés soufrés responsables d'odeurs etc.).

#### **4. La surveillance de la qualité des eaux**

La surveillance de la qualité de l'eau est définie comme l'échantillonnage et l'analyse des constituants et des conditions de l'eau. Les méthodes traditionnelles reposent sur la connaissance des différents paramètres caractéristiques de l'eau propre par des analyses chimiques réalisées en laboratoire, pour décider ultérieurement de son état et rechercher les techniques appropriées pour la rendre exploitable et potable.

Les inconvénients de ces méthodes sont qu'elles nécessitent l'intervention d'un expert humain et un temps suffisamment long qu'ils ne permettent pas de suivre finement et en permanence l'évolution de la qualité de l'eau propre. Le contrôle automatique effectué par un système de surveillance est considéré comme l'une des solutions efficaces pour résoudre de tels problèmes, car l'eau dans les usines de production doit être contrôlée immédiatement sur la base d'un suivi permanent des paramètres qualitatifs. Le contrôle automatique garantit à la fois l'efficacité du traitement et la réduction coûts d'exploitation. De plus, l'automatisation des processus de surveillance de la qualité de l'eau permet de pallier certaines faiblesses humaines et d'améliorer les conditions d'exploitation en supprimant le plus de tâches répétitives et pénibles pour l'opérateur. En outre, l'automatisation avec l'enrichissement éventuel et permanent de la base de données permet d'envisager des analyses statistiques des informations collectées, ouvrant ainsi la voie à des travaux de recherche de modélisation et améliorant ainsi les processus de traitement [14].

Récemment, le domaine de l'intelligence artificielle a été largement accueilli comme une alternative majeure à la surveillance de la qualité de l'eau lorsqu'il est nécessaire de prendre en compte l'intervention des experts du domaine ou de traiter l'information de nature qualitative.

##### **4.1. Méthodes de surveillance et de diagnostic**

Le développement de nouveaux outils à technologies avancées a compliqué l'automatisation des systèmes de surveillance, et rendre l'aspect temps réel difficile puisque ces systèmes intègrent à la fois du logiciel et du matériel conçus (systèmes embarqués). Le bon maintien de la

sécurité et du fonctionnement de ces systèmes en permanence sans interruption est devenu nécessaire et important. Il est nécessaire de trouver des informations dite "profondes" sur le comportement d'un tel système et de ses pannes, pour faciliter la tâche de la surveillance dans un but de diagnostic. L'objectif du diagnostic est d'identifier les premières causes d'un groupe de symptômes visibles qui indiquent la détérioration ou la défaillance de certains composants du système conduisant à un comportement anormal du système [14]. Généralement, les méthodologies de surveillance et de diagnostic se divisent en deux catégories principales: les méthodologies de surveillance et de diagnostic avec modèle et sans modèle [40]. Donc, il est souvent difficile de choisir l'approche convenable pour résoudre les différents problèmes de surveillance de diagnostic. Cependant, les méthodes de surveillance et de diagnostic basées sur des modèles dans un contexte dynamique sont souvent appropriés et préférables. Ces méthodes et le type de modèle associé se différencient non seulement par la nature des informations dont on dispose sur le système physique et ses défaillances, mais également par la manière dont cette connaissance est exploitée [14].

**Les techniques avec modèle:** ces techniques sont basées essentiellement sur l'existence d'un modèle formel du processus du système et utilisent généralement des techniques de modélisation automatisées [41].

**Les techniques sans modèle:** ces techniques se divisent en deux groupes. Le premier groupe comprend les outils de traitement statistique des signaux de bas niveau, car ces techniques sont en relation directe avec le signal fournie par le capteur, et ne servent généralement que pour la génération d'alarmes brutes sans aucune information transmise concernant leur signification [14]. La fonction de détection des défaillances est assurée seulement par des tests sur les signaux d'acquisition utilisant des outils statistiques. Le deuxième groupe est les techniques d'intelligence artificielle (IA) appelé techniques de haut niveau, qui sont utilisées comme des outils de base d'aide à la décision, également elles exigent l'existence d'un expert. Ces techniques ont la possibilité de détecter, interpréter et diagnostiquer les défaillances, leurs réponses sont donc plus élaborées et efficaces que celles des techniques de bas niveau [42]. La combinaison des approches automatiques avec les techniques d'IA peut comporter des nombreux avantages.

Dans ce contexte, de nombreuses classifications des méthodes de surveillance et de diagnostic sont proposées dans la littérature [43-45], cependant une classification globale est

montrée la figure 1.4. a classification de ces méthodes ne sont pas homogènes, elle est influencée en particulier par les domaines d'application à chaque communauté.

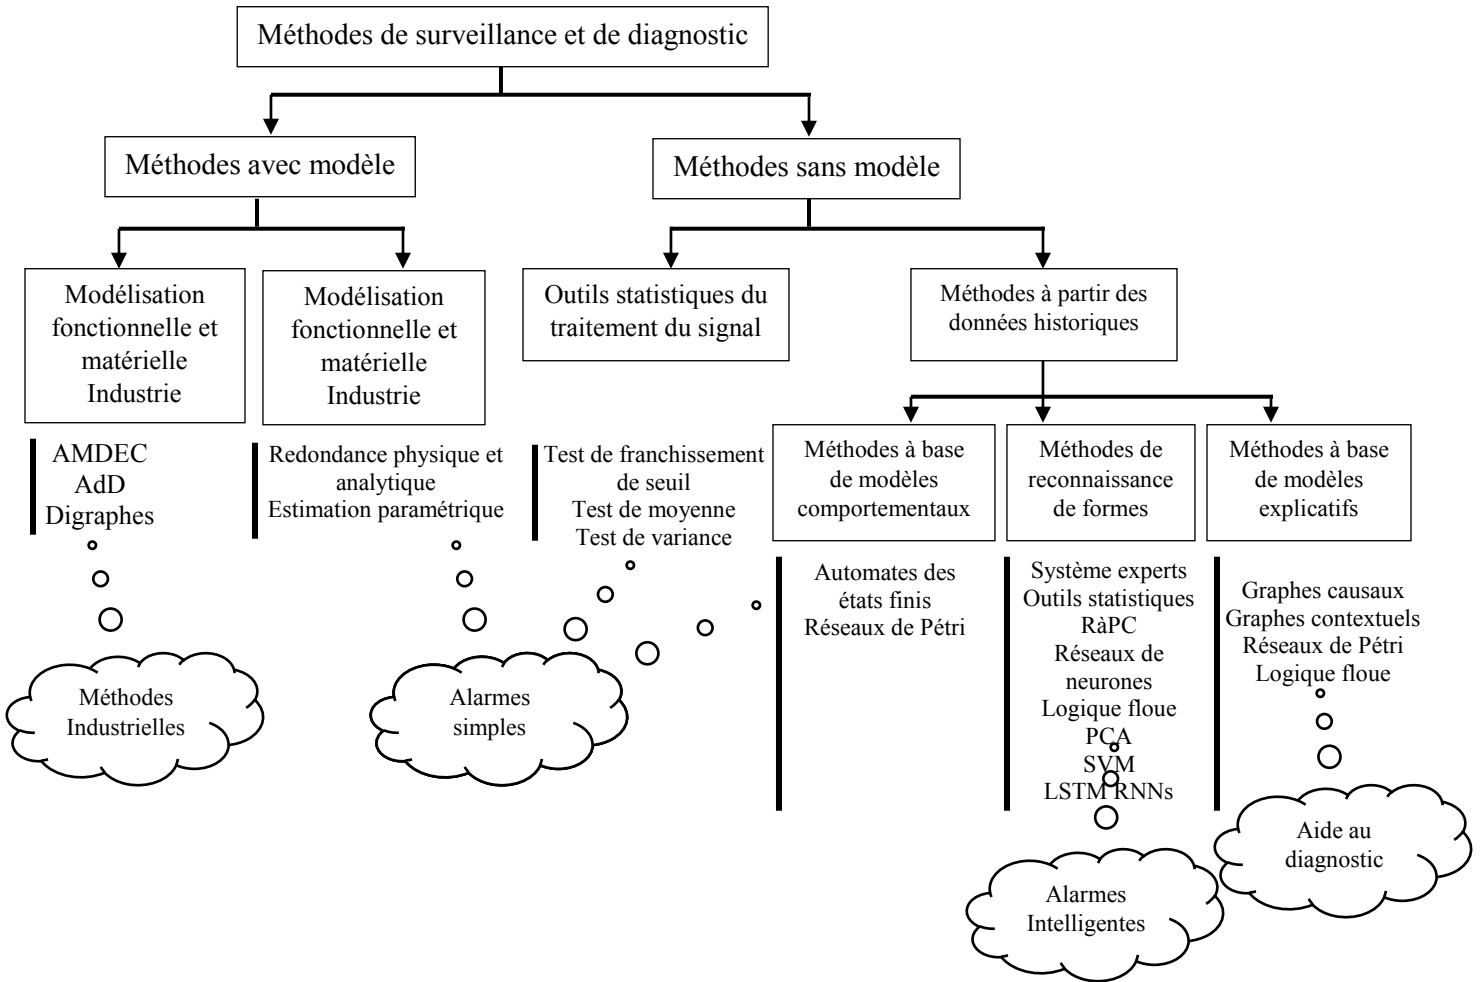


Figure 1.4. Classification globale des méthodes de surveillance et de diagnostic [14].

#### 4.1.1. Méthodes sans modèle

Dans certaines applications industrielles, le modèle du système est difficile à obtenir. Cette difficulté présente la complexité accrue due à de nombreuses reconfigurations intervenantes durant le processus de production. En fait, seules les méthodes de surveillance et de diagnostic sans modèles sont réalisables pour ce type d'application. Ces méthodes se basent sur des informations issues d'une expérience préalable, sur des règles heuristiques ou encore sur des exemples de résolution. Parmi ces méthodes, nous mentionnons:

**La méthode du seuillage:** cette méthode est basée sur la comparaison des signaux extraits des capteurs avec des valeurs limites constantes ou adaptatives [46-47]. Le premier niveau indique l'existence possible du défaut tandis que le second niveau peut discerner sa gravité. Le franchissement d'un seuil révèle la présence d'une anomalie.

**Les méthodes statistiques:** ces méthodes supposent que les signaux fournis par les capteurs ont certaines propriétés statistiques, sur la base desquelles les tests de seuil sont générés [47-49]. L'étude de l'évolution de la moyenne ou de la variance d'un signal peut favoriser la mise en évidence d'une anomalie.

**La reconnaissance de formes:** les méthodes de reconnaissance de formes sont basées sur l'utilisation des algorithmes de classification des mesures et des formes (discrètes ou continues). Le système de diagnostic de reconnaissance de formes fonctionne en trois étapes [50-58]:

- *La première étape:* l'étape d'analyse et elle consiste à identifier et minimiser l'espace de représentation des données et à déterminer l'espace de décision, ce qui permet d'identifier toutes les catégories possibles
- *La deuxième étape:* choisir une méthode de prise de décision permettant de définir la règle de décision qui a pour fonction de classer les nouvelles observations dans les différentes classes du groupe d'apprentissage
- *La troisième étape:* l'étape de fonctionnement qui détermine le mode de fonctionnement du système en fonction de chaque nouvelle observation recueillie dans le processus, en appliquant la règle de décision.

**Les systèmes experts:** ces systèmes utilisent des informations heuristiques pour lier les symptômes aux défauts. De plus, ces systèmes reposent sur des règles qui établissent des liens empiriques entre effets et causes [47]. Ces associations reposent généralement sur l'expertise de l'expert plutôt que sur la connaissance de la structure et / ou du comportement du système. La fonction des systèmes experts est de trouver la cause de ce qui a été observé en suivant les règles par un raisonnement inductif par chaînage avant ou arrière.

#### 4.1.2. Méthodes à base de modèle

Ces méthodes sont basées sur la comparaison du comportement du système au comportement du modèle qualitatif et / ou quantitatif établi, alors tout écart est synonyme de défaillance [47].

Selon le type du modèle (qualitatif et/ou quantitatif), on peut distinguer deux branches de méthodes : la méthode de la communauté de l'IA utilisant des modèles qualitatifs et la méthode quantitative issue de la communauté FDI (Failure Detection and Identification). La dissociation entre les méthodes qualitatives et quantitatives ne signifie pas que ces deux aspects sont séparés. En fait, ces deux types d'approches peuvent coexister dans une seule méthode de diagnostic.

### **Conclusion**

Dans ce chapitre, le concept d'eau propre et les différents paramètres utilisés dans sa surveillance, ainsi que les procédures de traitement et d'analyse de celle-ci, ont été présentés. Les différentes techniques existantes actuellement dans le domaine de la surveillance de la qualité de l'eau ont été présentées. Il a déjà été démontré qu'un contrôle automatique et permanent basé sur l'intelligence artificielle à travers des mesures quantifiables et qualifiables de l'eau peut offrir une solution plus élaborée et intéressante. Dans ce domaine, l'étape de réduction dimensionnelle (extraction et sélection des variables utiles et pertinentes) joue un rôle important dans l'amélioration du processus de surveillance automatique. Le chapitre suivant va porter sur les techniques les plus utilisées en réduction dimensionnelle.

## *Chapitre II*

# **REDUCTION DE DIMENSIONNALITE**

### **Introduction**

Actuellement, le contrôle et la surveillance permanente basée sur l'intelligence artificielle à partir de mesures quantifiables et qualifiables de l'eau est une alternative prometteuse pour la décision intelligente sur la qualité de l'eau en temps réel. Le problème de surveillance de la qualité de l'eau à travers des paramètres descripteurs peut être considéré comme un problème de reconnaissance de formes par classification, où les classes correspondent aux différents états de l'eau, et les formes représentent l'ensemble des caractéristiques de celle-ci. Le recueil des différents paramètres nécessaires de qualité de l'eau permet de faire une méthodologie d'analyse et de surveillance complète basée sur l'interprétation des informations obtenues. Dans ce contexte, l'étape de réduction dimensionnelle joue un rôle efficace dans l'amélioration des performances des techniques de reconnaissance de formes. La minimisation des dimensions de la base de données en extrayant et en sélectionnant des variables utiles et pertinentes permet de construire des modèles fiables et de haute-fidélité. Ceci, à son tour, garantit une bonne surveillance de la qualité de l'eau et simplicité de mise en oeuvre à moindre coût.

Dans ce chapitre, le problème d'avoir un grand nombre de dimension dans un espace de caractéristiques est abordé. Après cela, diverses méthodes de réduction de dimension sont discutées. Présentés comme étant des méthodes de réduction dimensionnelle pouvant être profitable aux systèmes de surveillance pour extraire et sélectionner des caractéristiques sont abordées.


### **1. Problème avec de nombreuses variables d'entrée**

Les performances des algorithmes d'apprentissage automatique peuvent se dégrader avec trop de variables d'entrée. Avoir un grand nombre de dimensions dans l'espace des caractéristiques peut signifier que le volume de cet espace est très grand et, à leur tour, les points que nous avons dans cet espace (lignes de données) représentent souvent un petit

échantillon non représentatif. Cela peut avoir un impact considérable sur les performances de l'ajustement des algorithmes d'apprentissage automatique sur des données avec de nombreuses caractéristiques d'entrée, généralement appelées : la «*malédiction de la dimensionnalité*». Par conséquent, il est souvent souhaitable de réduire le nombre de dimensions de l'espace des caractéristiques d'entrée. Cela appelée : *réduction de dimensionnalité* [59].

## 2. Techniques de réduction de dimensionnalité

Les techniques de réduction de dimensionnalité ou de réduction des variables se réfèrent simplement au processus de réduction du nombre de dimensions d'entités dans un ensemble de données. La réduction de dimensionnalité est la transformation des données d'un espace de grande dimension en un espace de faible dimension afin que la représentation de faible dimension conserve certaines propriétés significatives des données d'origine, idéalement proches de sa dimension intrinsèque [19]. Il est couramment utilisé lors de l'analyse de données de grande dimension (par exemple, des images multipixels d'un visage ou des textes d'un article, des catalogues astronomiques, etc.) [60]. Il existe deux façons de réduire la dimensionnalité: l'extraction et la sélection de caractéristiques [59] (comme le montre la figure 2.1).




**Figure 2.1.** Système de reconnaissance de formes comprenant la sélection et l'extraction des caractéristiques.

### 2.1. Extraction de caractéristiques

L'extraction de caractéristiques est la transformation des données dans l'espace de grande dimension en un espace de moins de dimensions qui comprend la plupart des informations précieuses [16]. Ceci est illustré à la figure 2.2. Une bonne caractéristique devrait rester inchangée si des variations ont lieu au sein d'une classe, et elle devrait révéler des différences importantes lors de la discrimination entre les formes de différentes classes. En d'autres

termes, les formes sont décrits avec le moins de perte possible d'informations pertinentes. Il existe de nombreuses méthodes d'extraction de caractéristiques bien connues, dont les plus courantes sont : Analyse en composantes principales (PCA), Analyse discriminante linéaire (LDA) et Analyse en composantes indépendantes (ICA) [15-17].



**Figure 2.2.** Réduction de dimensionnalité basée sur l'extraction de caractéristiques.

### 2.1.1. Analyse en composantes principales

L'analyse en composantes principales est une technique de base utilisée pour la réduction des données dans la reconnaissance de formes, le traitement du signal et la bio-ingénierie. Il a été largement utilisé dans l'analyse et la compression de données [61, 62]. Le PCA est également appelée transformation de Karhunen-Loève (KL) ou transformation de Hotelling [63]. L'idée est que des formes d'entrée similaires appartiennent à la même classe. Ainsi, les données d'entrée peuvent être normalisées dans l'intervalle unitaire, puis choisies en fonction de leurs variances. En ce sens, plus les variances sont importantes, meilleures sont les propriétés discriminatoires des entités en entrée.

L'objectif de la technique PCA est de trouver un espace de dimension inférieure ( $W$ ) qui est utilisé pour transformer les données  $X = \{x_1, x_2, \dots, x_n\}$  d'un espace de dimension supérieure ( $\mathbb{R}^M$ ) à un espace de dimension inférieure ( $\mathbb{R}^K$ ), où  $n$  représente le nombre total d'échantillons et  $x_i$  représente le  $i^{\text{ème}}$  échantillon ou observation. Tous les échantillons ont la même dimension ( $x_i \in \mathbb{R}^M$ ). La direction de l'espace PCA représente la direction de la variance maximale des données, comme le montre la figure 2.3. L'espace PCA est composé d'un certain nombre de composantes principales (CPs). Chaque composante principale a une robustesse différente selon la quantité de variance dans sa direction.

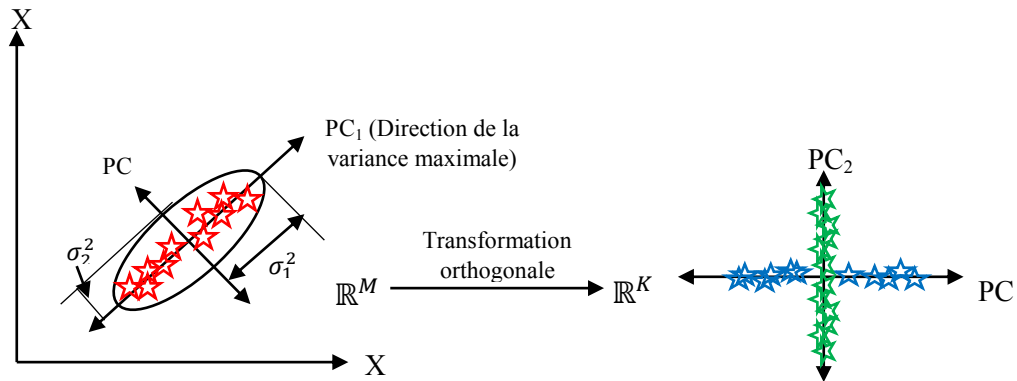


Figure 2.3. Un exemple de la technique PCA.

### Concepts de base

De manière générale, la mise en œuvre de la PCA consiste à [14]:

- **Etape 1** : Calculer la matrice de covariance (matrice COV);
- **Etape 2** : Calculer les vecteurs et les valeurs propres de la matrice de covariance;
- **Etape 3** : Former les axes principaux (nouvel espace propre) par les premiers vecteurs propres correspondant aux plus grandes valeurs propres.

#### Etape 1 : Calcul de la matrice de covariance (COV)

Soit la donnée  $x = [x_1, x_2, \dots, x_n]^T$ , avec  $x \in \mathbb{R}^{n \times p}$ . Ces données peuvent être structurées en une matrice, avec  $p$  lignes et  $n$  colonnes :

$$x = \begin{bmatrix} x_{1,1} & \cdots & x_{1,n} \\ \vdots & \ddots & \vdots \\ x_{p,1} & \cdots & x_{p,n} \end{bmatrix} \quad (2.1)$$

La variance de toute variable mesure l'écart de cette variable par rapport à sa valeur moyenne et est définie comme suit [64]:

$$\sigma^2(x) = \text{Var}(x) = E((x - \mu)^2) = E\{x^2\} - (E\{x\})^2 \quad (2.2)$$

où  $E(x)$  représente la valeur attendue de  $x$  et  $\mu$  représente la moyenne de la variable  $x$  et est définie comme suit [65]:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.3)$$

La matrice de covariance est utilisée lorsque le nombre de variables plus d'une fois et il est défini comme suit [66]:

$$COV_{ij} = E\{x_i x_j\} - E\{x_i\}E\{x_j\} = E[(x_i - \mu_i)(x_j - \mu_j)] \quad (2.4)$$

Comme le montre la figure 2.4, étape (A), après avoir calculé la moyenne de chaque variable dans la matrice de données, les données centrées sur la moyenne sont calculées en soustrayant la moyenne de chaque échantillon comme suit [65, 67]:

$$D = \{d_1, d_2, \dots, d_N\} = \{x_1 - \mu, x_2 - \mu, \dots, x_N - \mu\} \quad (2.5)$$

La matrice de covariance est ensuite calculée comme suit (voir figure 2.4, étape (B)) [64]:

$$Cov = DD^T \quad (2.6)$$

La matrice de covariance est une matrice symétrique (c'est-à-dire  $X = X^T$ ) et une matrice semi-définie toujours positive. Les valeurs diagonales de la matrice de covariance représentent la variance de la variable, tandis que les entrées hors diagonale représentent la covariance entre deux variables différentes, comme indiqué dans l'équation (2.7). Une valeur positive dans la matrice de covariance signifie une corrélation positive entre les deux variables, tandis que la valeur négative indique une corrélation négative et la valeur zéro indique que les deux variables ne sont pas corrélées ou statistiquement indépendantes [67].

$$\begin{pmatrix} Var(x_1, x_1) & Cov(x_1, x_2) & \cdots & Cov(x_1, x_M) \\ Cov(x_2, x_1) & Var(x_2, x_2) & \cdots & Cov(x_2, x_M) \\ \vdots & \vdots & \ddots & \vdots \\ Cov(x_M, x_1) & Cov(x_M, x_2) & \cdots & Var(x_M, x_M) \end{pmatrix} \quad (2.7)$$

### **Etape 2 : Calcul des valeurs propres ( $\lambda$ ) et des vecteurs propres ( $V$ )**

La matrice de covariance est résolue en calculant les valeurs propres ( $\lambda$ ) et les vecteurs propres ( $V$ ) comme suit [59]:

$$V \times Cov = \lambda V \quad (2.8)$$

où  $\lambda$  et  $V$  représentent les valeurs propres et les vecteurs propres de la matrice de covariance respectivement.

Les valeurs propres sont des valeurs scalaires, tandis que les vecteurs propres sont des vecteurs non nuls, qui représentent les composantes principales, c'est-à-dire que chaque vecteur propre représente une composante principale. Les vecteurs propres représentent les directions de l'espace PCA et les valeurs propres correspondantes représentent le facteur d'échelle des vecteurs propres. Le vecteur propre avec la valeur propre la plus élevée représente la première composante principale et il a la variance maximale. Les valeurs propres peuvent être égales lorsque les CPs ont des variances égales et donc tous les vecteurs propres sont les mêmes et nous ne pouvons pas décider quels vecteurs propres sont utilisés pour construire l'espace PCA [64].

### ***Etape 3 : Espace PCA (espace de dimension inférieure)***

Pour construire l'espace de dimension inférieure de le PCA, une combinaison linéaire de  $k$  CP sélectionnés qui ont le plus de  $k$  valeurs propres sont utilisées pour préserver le maximum de variance, c'est-à-dire préserver les données d'origine, tandis que les autres vecteurs propres ou CP sont négligés comme indiqué dans figure 2.4 (étape C). L'espace de dimension inférieure est noté  $W = \{v_1, v_2, \dots, v_k\}$ . La dimension des données d'origine est réduite en les projetant après avoir soustrait la moyenne sur l'espace PCA comme dans l'équation (2.9) [64].

$$Y = W^T D \quad (2.9)$$

où  $Y$  représente les données d'origine après les avoir projetées sur l'espace PCA, comme le montre la figure 2.5, ainsi  $(M - k)$  les caractéristiques ou les variables sont perdues dans les données d'origine.

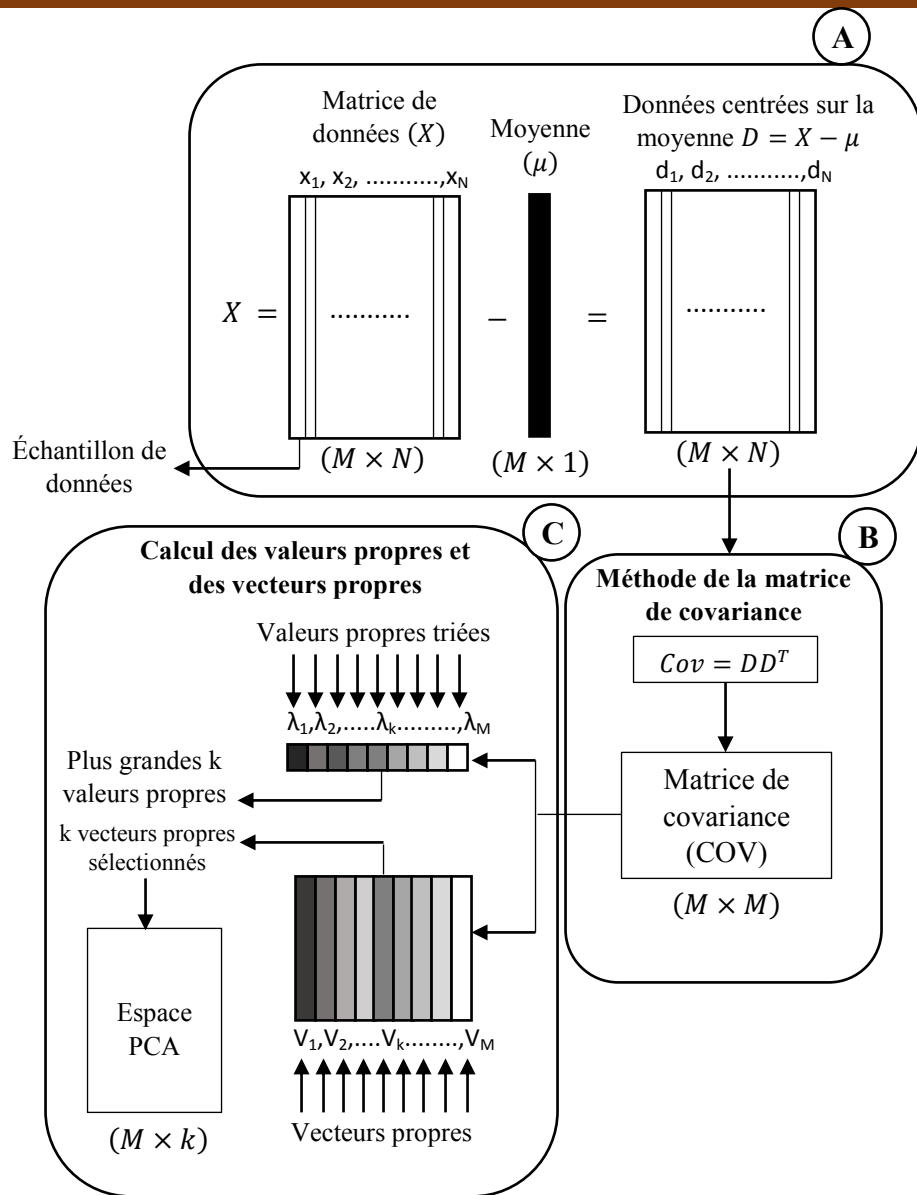


Figure 2.4. Étapes visualisées pour calculer l'espace PCA à l'aide de la méthode de la matrice de covariance [64].

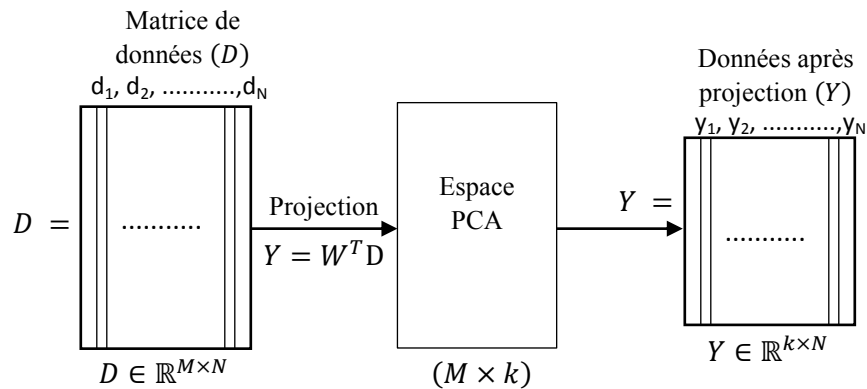


Figure 2.5. Projection des données en PCA [64].

### 2.1.2. Analyse discriminante linéaire

L'analyse discriminante linéaire (LDA), l'analyse discriminante normale ou l'analyse de fonction discriminante est une généralisation du discriminant linéaire de Fisher, une méthode utilisée dans les statistiques et d'autres domaines, pour trouver une combinaison linéaire de caractéristiques qui caractérise ou sépare deux ou plusieurs classes d'objets ou d'événements. La combinaison résultante peut être utilisée comme classificateur linéaire ou, pour la réduction de la dimensionnalité avant la classification.

La technique LDA est développée pour transformer les caractéristiques en un espace de dimension inférieure, ce qui maximise le rapport de la variance inter-classe à la variance intra-classe, garantissant ainsi une séparabilité maximale des classes [68]. Il existe deux types de techniques LDA pour gérer les classes: dépendantes des classes et indépendantes des classes. Dans la LDA dépendant de la classe, un espace de dimension inférieure distinct est calculé pour chaque classe afin de projeter ses données dessus tandis que, dans la LDA indépendant de la classe, chaque classe sera considérée comme une classe distincte par rapport aux autres classes [69]. Dans ce type, il n'y a qu'un seul espace de dimension inférieure pour que toutes les classes y projettent leurs données.

#### 2.1.2.1. Définition

L'objectif de la technique LDA est de projeter la matrice de données d'origine sur un espace de dimension inférieure. Pour atteindre cet objectif, trois étapes devaient être réalisées [70]. La première étape consiste à calculer la séparabilité entre les différentes classes (c'est-à-dire la distance entre les moyennes des différentes classes), appelée matrice interclasse (variance interclasse). La deuxième étape consiste à calculer la distance entre la moyenne et les échantillons de chaque classe, appelée matrice intra-classe (variance intra-classe). La troisième étape consiste à construire l'espace de dimension inférieure qui maximise la variance inter-classe et minimise la variance intra-classe [70].

- **Calcul de la variance interclasse ( $S_B$ )**

La variance inter-classe de la  $i^{\text{ème}}$  classe ( $S_{B_i}$ ) représente la distance entre la moyenne de la  $i^{\text{ème}}$  classe ( $\mu_i$ ) et la moyenne totale ( $\mu$ ). La technique LDA recherche un espace de dimension

inférieure, qui est utilisé pour maximiser la variance inter-classe, ou en d'autres termes maximiser la distance de séparation entre les classes.

Soit la matrice de données  $X_i = \{x_1, x_2, \dots, x_N\}$ , où  $x_i$  représente le  $i^{\text{ème}}$  échantillon et  $N$  est le nombre total d'échantillons. Chaque échantillon est représenté par  $M$  caractéristiques ( $X_i \in \mathbb{R}^M$ ). En d'autres termes, chaque échantillon est représenté comme un point dans l'espace à  $M$  dimensions. Supposons que la matrice de données soit divisée en  $c = 3$  classes comme suit,  $X = [\omega_1, \omega_2, \omega_3]$  comme le montre la figure 2.6 (étape (A)). Chaque classe a cinq échantillons (c'est-à-dire  $n_1 = n_2 = n_3 = 5$ ), où  $n_i$  représente le nombre d'échantillons de la  $i^{\text{ème}}$  classe.

Pour calculer la variance inter-classes ( $S_B$ ), la distance de séparation entre les différentes classes qui est dénotée ( $m_i - m$ ) sera calculée comme suit [70]:

$$(m_i - m)^2 = (W^T \mu_i - W^T \mu)^2 = W^T (\mu_i - \mu) (\mu_i - \mu)^T W \quad (2.10)$$

où  $m_i$  représente la projection de la moyenne de la  $i^{\text{ème}}$  classe et il est calculé comme suit :

$$m_i = W^T \mu_i \quad (2.11)$$

où  $m$  est la projection de la moyenne totale de toutes les classes et il est calculé comme suit :

$$m = W^T \mu \quad (2.12)$$

$W$  représente la matrice de transformation de LDA,  $\mu_i$  représente la moyenne de la  $i^{\text{ème}}$  classe et il est calculé comme suit [71]:

$$\mu_i = \frac{1}{n_i} \sum_{x_i \in \omega_i} x_i \quad (2.13)$$

$\mu$  est la moyenne totale de toutes les classes et il peut être calculé comme suit [71]:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2.14)$$

La figure 2.6 montre aux étapes (B) et (C) la moyenne de chaque classe et la moyenne totale, respectivement. Le terme  $(\mu_i - \mu)(\mu_i - \mu)^T$  dans l'équation (2.10) représente la

distance de séparation entre la moyenne de la  $i^{\text{ème}}$  classe ( $\mu_i$ ) et la moyenne totale ( $\mu$ ), ou simplement il représente la variance inter-classe de la  $i^{\text{ème}}$  classe ( $S_{B_i}$ ). Remplacez  $S_{B_i}$  dans l'équation (2.10) comme suit [71]:

$$(m_i - m)^2 = W^T S_{B_i} W \quad (2.15)$$

La variance totale inter-classe est calculée comme suit [70]:

$$S_B = \sum_{i=1}^c n_i S_{B_i} \quad (2.16)$$

La figure 2.6 (étape (D)) montre comment la matrice inter-classe de la première classe ( $S_{B_1}$ ) est calculée, puis comment la matrice inter-classe totale ( $S_B$ ) est ensuite calculée en additionnant toutes les matrices inter-classe de toutes les classes.

- **Calcul de la variance intra-classe ( $S_W$ )**

La variance intra-classe de la  $i^{\text{ème}}$  classe ( $S_{W_i}$ ) représente la différence entre la moyenne et les échantillons de cette classe. La technique LDA recherche un espace de dimension inférieure, qui est utilisé pour minimiser la différence entre la moyenne projetée ( $m_i$ ) et les échantillons projetés de chaque classe ( $W^T x_i$ ) ou en d'autres termes minimiser la variance intra-classe [71, 72]. The within-class variance of each class ( $S_{W_j}$ ) is calculated as follows [70]:

$$\begin{aligned} \sum_{x_i \in \omega_j, j=1, \dots, c} (W^T x_i - m_j)^2 &= \sum_{x_i \in \omega_j, j=1, \dots, c} (W^T x_{ij} - W^T \mu_j)^2 = \sum_{x_i \in \omega_j, j=1, \dots, c} W^T (x_{ij} - \mu_j)^2 W \\ &= \sum_{x_i \in \omega_j, j=1, \dots, c} W^T (x_{ij} - \mu_j)(x_{ij} - \mu_j)^T W = \sum_{x_i \in \omega_j, j=1, \dots, c} W^T S_{W_j} W \end{aligned} \quad (2.17)$$

À partir de l'équation (2.17), la variance intra-classe pour chaque classe peut être calculée comme suit [72]:

$$S_{W_j} = d_j^T \times d_j = \sum_{i=1}^{n_j} (x_{ij} - \mu_j)(x_{ij} - \mu_j)^T \quad (2.18)$$

où  $x_i$  représente le  $i^{\text{ème}}$  échantillon dans la  $j^{\text{ème}}$  classe comme le montre la figure 2.6 (étape (E), (F)), et  $d$  est les données de centrage de la  $j^{\text{ème}}$  classe, c'est-à-dire  $d_j = \omega_j - \mu_j = \{x_i\}_{i=1}^{n_j} - \mu_j$ . De plus, l'étape (F) de la figure illustre comment la variance intra-classe de la première classe ( $S_{W_1}$ ) est calculée. La variance intra-classe totale représente la somme de toutes les matrices intra-classes de toutes les classes (figure 2.6 (étape (F))), et elle peut être calculée comme suit [70]:

$$S_W = \sum_{i=1}^c S_{W_i} \quad (2.19)$$

- **Construire l'espace de dimension inférieure**

Après avoir calculé la variance inter-classe ( $S_B$ ) et la variance intra-classe ( $S_W$ ), la matrice de transformation ( $W$ ) de la technique LDA peut être calculée comme dans l'équation (2.20), appelée critère de Fisher [71, 72]:

$$\arg \max_W \frac{W^T S_B W}{W^T S_W W} \quad (2.20)$$

Cette formule peut être reformulée comme suit:

$$S_W W = \lambda S_B W \quad (2.21)$$

où  $\lambda$  représente les valeurs propres de la matrice de transformation ( $W$ ). La solution de ce problème peut être obtenue en calculant les valeurs propres ( $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_M\}$ ) et les vecteurs propres ( $V = \{v_1, v_2, \dots, v_M\}$ ) de  $W = S_W^{-1} S_B$ , si  $S_W$  est non singulier.

Les valeurs propres sont des valeurs scalaires, tandis que les vecteurs propres sont des vecteurs non nuls, ce qui satisfait l'équation (2.21) et nous fournit des informations sur l'espace LDA. Les vecteurs propres avec les  $k$  valeurs propres les plus élevées sont utilisés pour construire un espace de dimension inférieure ( $V_k$ ), tandis que les autres vecteurs propres ( $\{v_{k+1}, v_{k+2}, \dots, v_M\}$ ) sont négligés comme le montre la figure 2.6 (étape (G)).

La figure 2.7 montre l'espace de dimension inférieure de la technique LDA, qui est calculé comme sur la figure 2.6 (étape (G)). Comme indiqué, la dimension de la matrice de données

d'origine ( $X \in \mathbb{R}^{N \times M}$ ) est réduite en la projetant sur l'espace de dimension inférieure de LDA ( $V_k \in \mathbb{R}^{M \times k}$ ) comme indiqué dans l'équation (2.22). La dimension des données après projection est  $k$ ; par conséquent,  $M - k$  caractéristiques sont ignorées ou supprimées de chaque échantillon. Ainsi, chaque échantillon ( $V_k$ ) qui a été représenté comme un point d'un espace de dimension  $M$  sera représenté dans un espace de dimension  $k$  en le projetant sur l'espace de dimension inférieure ( $V_k$ ) comme suit [69]:

$$Y = XV_k \quad (2.22)$$

### 2.1.2.2. Algorithme LDA

Dans cette section, les étapes détaillées des algorithmes des deux méthodes LDA sont présentées. Comme le montrent les algorithmes 1 et 2, les quatre premières étapes des deux algorithmes sont les mêmes [70].

---

Algorithme 1. Analyse discriminante linéaire (LDA) : indépendante de la classe

---

1. Étant donné un ensemble de  $N$  échantillons  $[x_i]_{i=1}^N$ , dont chacun est représenté par une ligne de longueur  $M$ , et  $X(N \times M)$  est donné par :

$$X = \begin{bmatrix} x(1,1) & x(1,2) & \cdots & x(1,M) \\ x(2,1) & x(2,2) & \cdots & x(2,M) \\ \vdots & \vdots & \vdots & \vdots \\ x(N,1) & x(N,2) & \cdots & x(N,M) \end{bmatrix} \quad (2.23)$$

2. Calculer la moyenne de chaque classe  $\mu_i$ .
3. Calculer la moyenne totale  $\mu$  de toutes les données.
4. Calculer la matrice inter-classe  $S_B$  comme suit :

$$S_B = \sum_{i=1}^c n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.24)$$

5. Calculer le  $S_W$  de la matrice intra-classe comme suit :

$$S_W = \sum_{j=1}^c \sum_{i=1}^{n_j} (x_{ij} - \mu_j)(x_{ij} - \mu_j)^T \quad (2.25)$$

6. A partir d'équation (2.24) et (2.25) la matrice  $w$  qui maximisant la formule de Fisher qui est définie dans l'équation (2.20) est calculée comme suit,  $W = S_W^{-1} S_B$ . Les valeurs propres ( $\lambda$ ) et les vecteurs propres ( $V$ ) de  $W$  sont ensuite calculés.
  7. Tri des vecteurs propres par ordre décroissant selon leurs valeurs propres correspondantes. Les  $k$  premiers vecteurs propres sont alors utilisés comme espace de dimension inférieure ( $V_k$ ).
  8. Projetez tous les échantillons originaux ( $X$ ) sur l'espace de dimension inférieure de LDA.
-

---

Algorithme 2. Analyse discriminante linéaire (LDA) : dépendant de la classe

---

1. Étant donné un ensemble de  $N$  échantillons  $[x_i]_{i=1}^N$ , dont chacun est représenté par une ligne de longueur  $M$ , et  $X(N \times M)$  est donné par :

$$X = \begin{bmatrix} x(1,1) & x(1,2) & \cdots & x(1,M) \\ x(2,1) & x(2,2) & \cdots & x(2,M) \\ \vdots & \vdots & \vdots & \vdots \\ x(N,1) & x(N,2) & \cdots & x(N,M) \end{bmatrix} \quad (2.26)$$

2. Calculer la moyenne de chaque classe  $\mu_i$ .  
 3. Calculer la moyenne totale  $\mu$  de toutes les données.  
 4. Calculer la matrice inter-classe  $S_B$  comme dans l'équation (2.24).  
 5. **Pour toute classe  $i$ ,  $i = 1, 2, \dots, c$  faire**  
 6. Calculer la matrice intra-classe ( $S_{W_i}$ ) de chaque classe, comme suit :

$$S_{W_i} = \sum_{x_i \in \omega_j} (x_i - \mu_j)(x_i - \mu_j)^T \quad (2.27)$$

7. Construisez une matrice de transformation pour chaque classe ( $W_i$ ) comme suit :

$$W_i = S_{W_i}^{-1} S_B \quad (2.28)$$

8. Les valeurs propres ( $\lambda^i$ ) et les vecteurs propres ( $V^i$ ) de chaque matrice de transformation ( $W_i$ ) sont ensuite calculés, où  $\lambda^i$  et  $V^i$  représentent respectivement les valeurs propres et les vecteurs propres calculés de la  $i^{\text{ème}}$  classe.  
 9. Tri des vecteurs propres par ordre décroissant selon leurs valeurs propres correspondantes. Les  $k$  premiers vecteurs propres sont ensuite utilisés pour construire un espace de dimension inférieure pour chaque classe ( $V_k^i$ ).  
 10. Projetez les échantillons de chaque classe ( $\omega_i$ ) sur leur espace de dimension inférieure ( $V_k^i$ ), comme suit :

$$Y_i = x_i V_k^j, \quad x_i \in \omega_j \quad (2.29)$$

où  $Y_i$  représente les échantillons projetés de la classe  $\omega_j$ .

11. fin pour
-

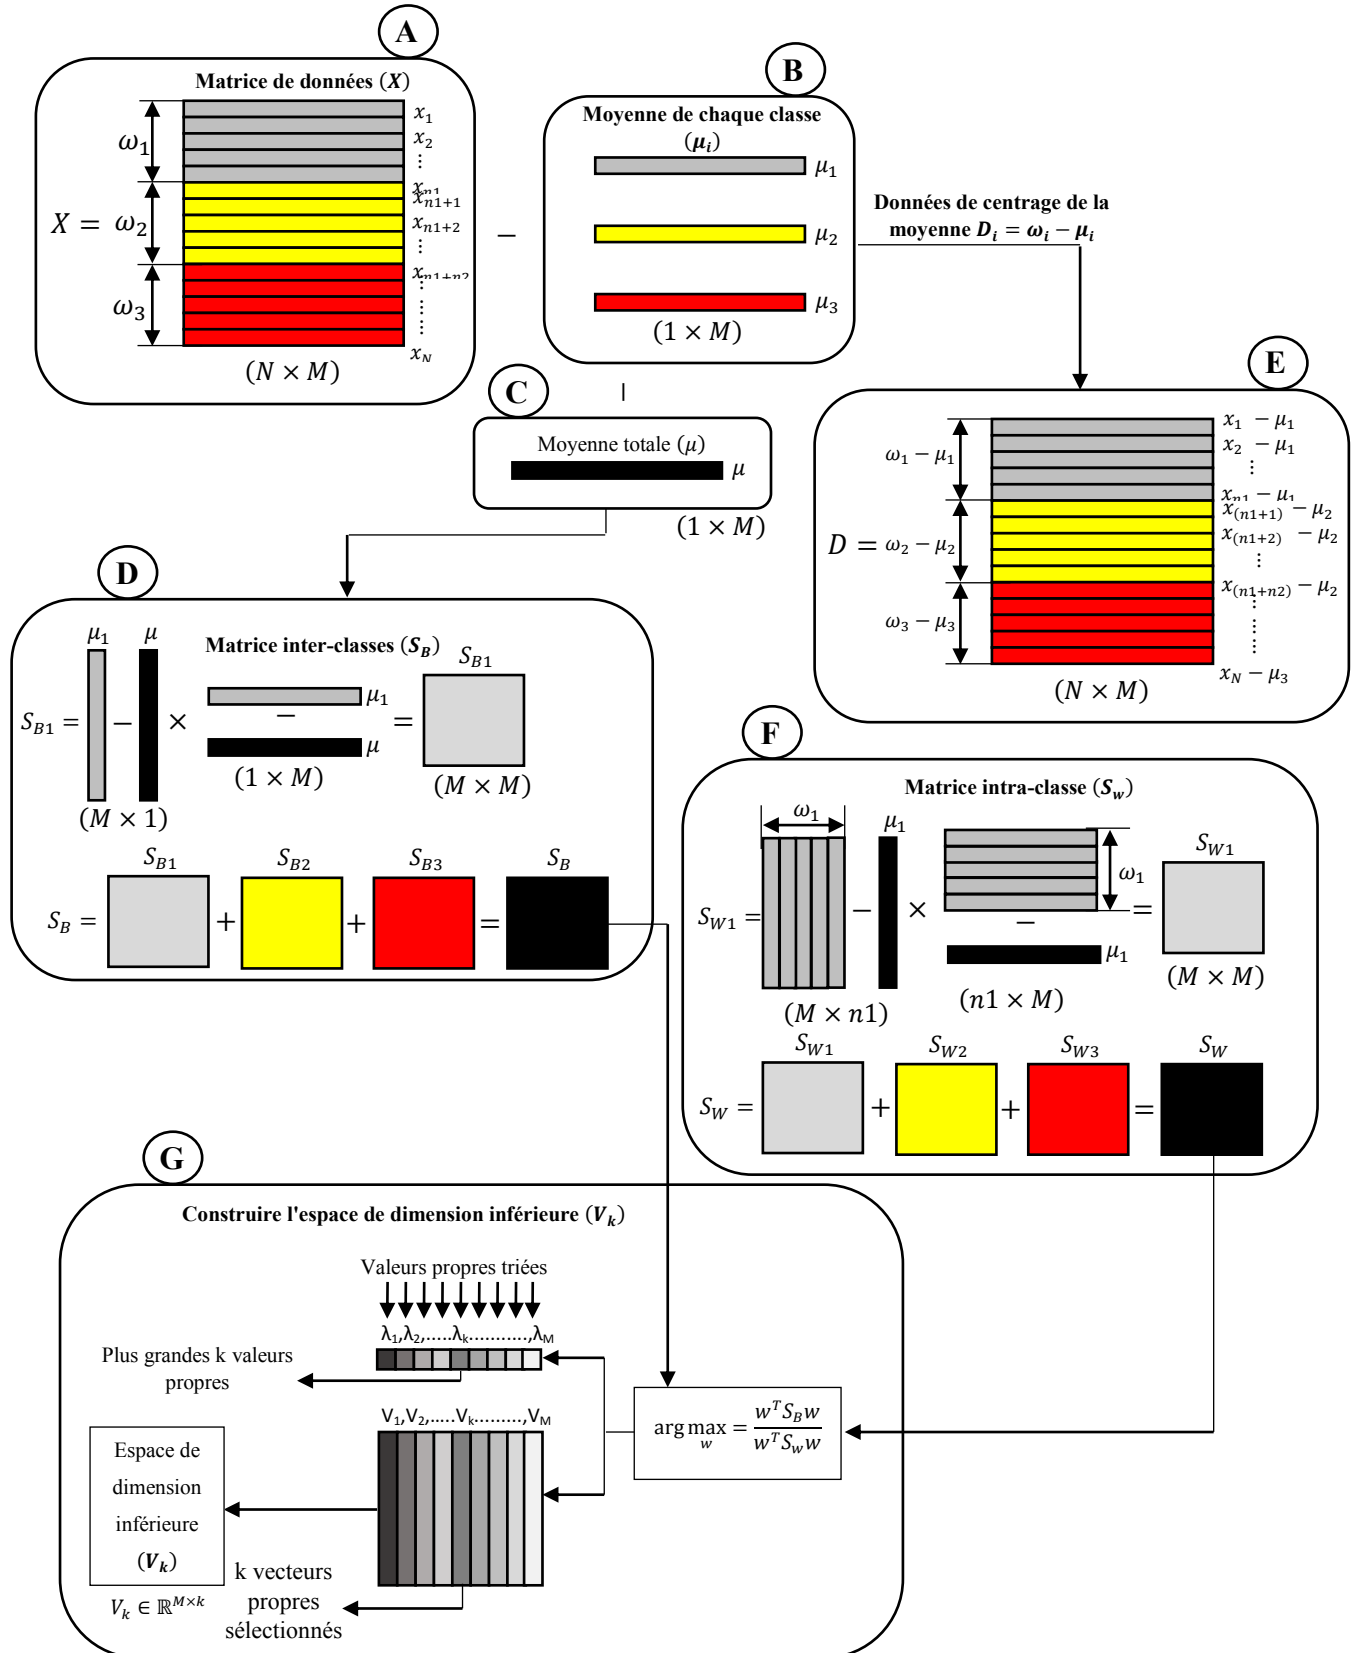


Figure 2.6. Etapes visualisées pour calculer un sous-espace de dimension inférieure de la technique

LDA [70].

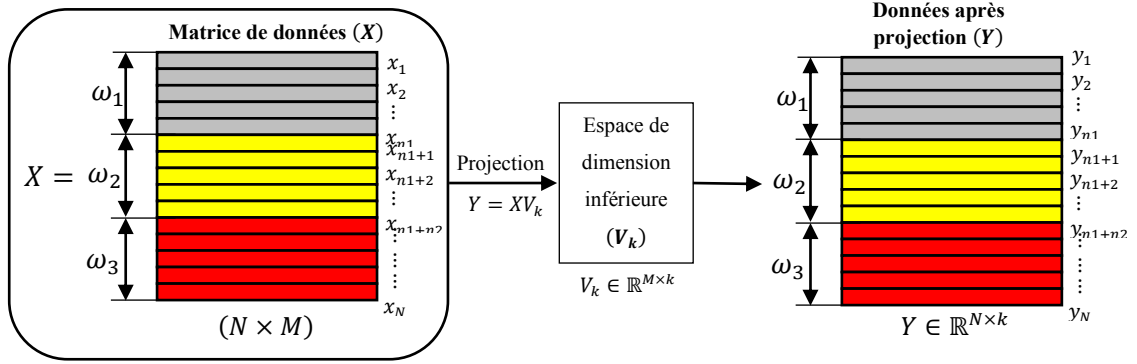


Figure 2.7. Projection des échantillons originaux sur l'espace de dimension inférieure de LDA [70].

### 2.1.3. Analyse en composantes indépendantes

L'analyse en composantes indépendantes (ICA) est une technique de séparation aveugle de source largement utilisée [73]. L'ICA a été introduit dans les années 80 par J. Héroult, C. Jutten et B. Ans [74]. L'ICA est une technique qui transforme un signal aléatoire multivarié en un signal ayant des composantes mutuellement indépendantes dans un sens statistique complet. Récemment, il a été démontré que cette technique est capable d'extraire des composantes indépendantes de signaux mixtes. Ici, l'indépendance signifie que l'information portée par un composant ne peut pas être déduite des autres. Statistiquement, cela signifie que la probabilité conjointe de grandeurs indépendantes est obtenue comme le produit de la probabilité de chacune d'elles. Un modèle ICA générique peut être écrit sous la forme [59, 75]:

$$x = As \tag{2.30}$$

où  $x = [x_1, x_2, \dots, x_n]^T$  est connu pour être la matrice des signaux observés,  $s = [s_1, s_2, \dots, s_n]^T$  est la matrice des signaux de source inconnue et  $A$  est une matrice constante inconnue, appelée matrice de mélange. Si les colonnes de la matrice  $A$  sont notées  $a_i$  le modèle peut donc être présenté comme [76, 77]:

$$x = \sum_{i=1}^n a_i s_i \tag{2.31}$$

L'objectif de l'ICA est d'estimer  $s$  par :

$$s = Wx \tag{2.32}$$

afin que les composantes de la matrice  $s$  soient aussi statistiquement indépendantes que possible.  $W$  est appelé la matrice  $m \times m$  de démélange.

### 2.1.3.1. Phase de prétraitement

Cette phase comporte deux étapes principales : le centrage et le blanchiment [78].

#### a. L'étape de centrage

Le but de cette étape est de centrer les données en soustrayant la moyenne de tous les signaux. Etant donné  $n$  signaux de mélange ( $X$ ), la moyenne est  $l$  et le pas de centrage peut être calculé comme suit [76, 78]:

$$D = X - \mu = \begin{pmatrix} d_1 \\ d_2 \\ \vdots \\ d_n \end{pmatrix} - \begin{pmatrix} x_1 - \mu \\ x_2 - \mu \\ \vdots \\ x_n - \mu \end{pmatrix} \quad (2.33)$$

où  $D$  est les signaux de mélange après l'étape de centrage comme sur la figure 2.8 (étape A), et  $\mu \in \mathbb{R}^{1 \times N}$  est la moyenne de tous les signaux de mélange. Le vecteur moyen peut être rajouté aux composants indépendants après l'application de l'ICA.

#### b. Étape de blanchiment des données

Cette étape vise à blanchir les données, ce qui signifie transformer les signaux en signaux non corrélés, puis redimensionner chaque signal pour qu'il soit avec une variance unitaire. Cette phase comprend deux étapes principales comme suit:

**Décorrélation :** Le but de cette étape est de décorrélérer les signaux ; en d'autres termes, rendre chaque signal non corrélé entre eux. Deux variables aléatoires sont considérées comme non corrélées si leur covariance est nulle. En ICA, la technique PCA peut être utilisée pour décorrélérer les signaux. En PCA, les vecteurs propres qui forment le nouvel espace PCA sont calculés.

En PCA, d'abord, la matrice de covariance est calculée. La matrice de covariance de deux variables  $(x_i x_j)$  quelconques est définie comme suit [64]:

$$COV_{ij} = E\{x_i x_j\} - E\{x_i\}E\{x_j\} = E[(x_i - \mu_i)(x_j - \mu_j)] \quad (2.34)$$

Avec de nombreuses variables, la matrice de covariance est calculée comme suit [64]:

$$COV = E[DD^T] \quad (2.35)$$

où  $D$  est la donnée centrée (voir figure 2.8 (étape B)). La matrice de covariance est résolue en calculant les valeurs propres ( $k$ ) et les vecteurs propres ( $V$ ) comme suit [59]:

$$V \times COV = \lambda V \quad (2.36)$$

où les vecteurs propres représentent les composantes principales qui représentent les directions de l'espace PCA et les valeurs propres sont des valeurs scalaires qui représentent l'amplitude des vecteurs propres. Le vecteur propre qui a la valeur propre maximale est la première composante principale ( $CP_1$ ) et il a la variance maximale. Pour décorréler les signaux de mélange, ils sont projetés sur l'espace PCA calculé comme suit [76, 78]:

$$U = VD \quad (2.37)$$

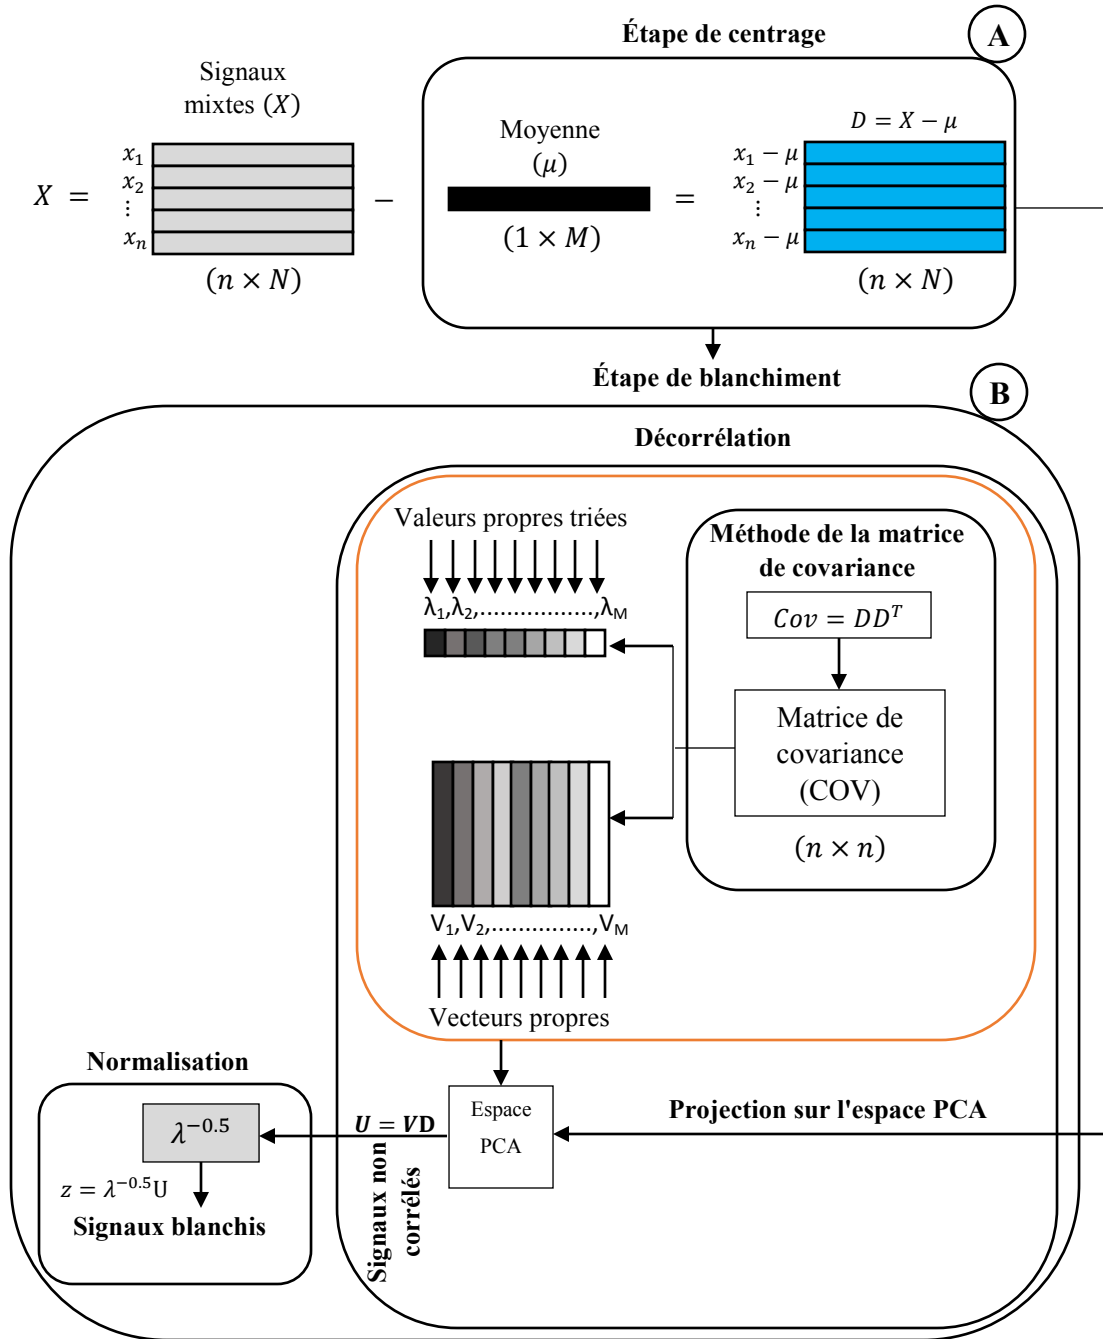
**Mise à l'échelle:** le but ici est de mettre à l'échelle chaque signal décorrélé avec une variance unitaire. Par conséquent, chaque vecteur dans  $U$  a une longueur unitaire et est ensuite rééchelonné pour être avec une variance unitaire comme suit [76, 78]:

$$Z = \lambda^{-\frac{1}{2}}U = \lambda^{-\frac{1}{2}}VD \quad (2.38)$$

où  $Z$  est les données blanchies ou sphériques et  $\lambda^{-\frac{1}{2}}$  est calculé par une simple opération par composant comme suit [76, 78]:

$$\lambda^{-\frac{1}{2}} = \left\{ \lambda_1^{-\frac{1}{2}}, \lambda_2^{-\frac{1}{2}}, \dots, \lambda_n^{-\frac{1}{2}} \right\} \quad (2.39)$$

Après l'étape de mise à l'échelle, les données deviennent symétriques en rotation comme une sphère ; par conséquent, l'étape de blanchiment est également appelée sphérique.



**Figure 2.8.** Visualisation des étapes de prétraitement dans ICA. (A) l'étape de centrage, (B) L'étape de blanchiment [78].

### 2.1.3.2. Principe de l'estimation ICA

Dans ICA, l'objectif est de trouver la matrice de démixage ( $W$ ) puis de projeter les données blanchies sur cette matrice pour extraire des signaux indépendants. Cette matrice peut être estimée en utilisant trois approches principales de l'indépendance, qui conduisent à des

matrices de démixage légèrement différentes. La première est basée sur la non-gaussianité. Cela peut être mesuré par certaines mesures telles que la néguentropie et le kurtosis, et le but de cette approche est de trouver des composants indépendants qui maximisent la non-gaussianité [79, 80]. Dans la seconde approche, l'objectif ICA peut être obtenu en minimisant l'information mutuelle [81]. Les composantes indépendantes peuvent également être estimées en utilisant l'estimation du maximum de vraisemblance (MV) [82]. Parmi ces trois méthodes, la maximisation de la non-gaussianité est la meilleure et la plus utilisée.

### **Mesures de non-gaussianité**

La recherche de composants indépendants peut être réalisée en maximisant la non-gaussianité des signaux extraits [83]. Une méthode de mesure de la non-gaussianité consiste à maximiser l'entropie négative et c'est la méthode la plus utilisée.

### **Entropie négative**

L'entropie négative est appelée néguentropie et est définie comme suit [84]:

$$J(y) = H(y_{gauss}) - H(y) \quad (2.40)$$

où  $H$  est l'entropie d'une variable aléatoire gaussienne dont la matrice de covariance est égale à la matrice de covariance de  $y$ . L'entropie d'une variable aléatoire  $Q$  qui a  $N$  résultats possibles est [84]:

$$H(Q) = -E[\log p_q(q)] = -\frac{1}{N} \sum_t^N \log p_q(q^t) \quad (2.41)$$

où  $p_q(q^t)$  est la probabilité de l'événement  $q^t, t = 1, 2, \dots, N$ .

La néguentropie est nulle lorsque toutes les variables sont gaussiennes, c'est-à-dire  $H(y_{gauss}) = H(y)$ . La néguentropie est toujours non négative car l'entropie de la variable gaussienne est le maximum parmi toutes les autres variables aléatoires avec la même variance. De plus, il est invariant pour la transformation linéaire inversible et il est invariant à l'échelle [85]. Cependant, le calcul de l'entropie à partir d'une donnée finie est difficile en termes de calcul. Par conséquent, différentes approximations ont été introduites pour le calcul de la néguentropie [85]. Par exemple:

$$J(y) \approx \frac{1}{12}E[y^3]^2 + \frac{1}{48}k(y)^2 \quad (2.42)$$

où  $y$  est supposé être de moyenne nulle. Cette approximation souffre de la sensibilité du kurtosis; par conséquent, Hyvarinen a proposé une autre approximation basée sur le principe d'entropie maximale comme suit [83]:

$$J(y) \approx \sum_{i=1}^p k_i (E[G_i(y)] - E[G_i(v)])^2 \quad (2.43)$$

où  $k_i$  est des constantes positives,  $v$  indique une variable gaussienne avec une moyenne nulle et une variance unitaire,  $G_i$  représente des fonctions quadratiques. La fonction  $G$  a différents choix tels que [85]:

$$G_1(y) = \frac{1}{a_1} \log(\cosh(a_1 y)) \quad (2.44)$$

$$G_2(y) = -\frac{1}{a_2} \exp(-a_2 y^2 / 2) \quad (2.45)$$

$$G_3(y) = \frac{1}{4} y^4 \quad (2.46)$$

où  $1 \leq a_1 \leq 2$ ,  $a_2 \approx 1$  sont des constantes. Ces fonctions sont largement utilisées, et ces approximations donnent un très bon compromis entre les propriétés de kurtosis et de néguentropie qui sont les deux mesures classiques de non-gaussianité.

### 2.1.3.3. Algorithmes ICA

Il existe de nombreux algorithmes ICA. L'une des meilleures méthodes est l'algorithme à virgule fixe FastICA [73].

#### *FastICA*

L'algorithme FastICA extrait des composants indépendants en maximisant la non-gaussianité en maximisant la néguentropie pour les signaux extraits à l'aide d'un schéma d'itération à virgule fixe [80]. FastICA a une vitesse de convergence cubique ou au moins quadratique et est donc beaucoup plus rapide que les algorithmes basés sur le gradient qui ont

une convergence linéaire. De plus, FastICA n'a pas de taux d'apprentissage ou d'autres paramètres réglables, ce qui le rend facile à utiliser. FastICA peut être utilisé pour extraire un CI, c'est ce qu'on appelle une unité, où FastICA trouve le vecteur de poids ( $w$ ) qui extrait un composant indépendant. Les valeurs de  $w$  sont mises à jour par une règle d'apprentissage qui recherche une direction qui maximise la non-gaussianité.

La dérivée de la fonction  $G$  dans l'équation. (2.43) est noté  $g$ , et les dérivées pour  $G_1$  et  $G_2$  dans l'Eq. (2.44) et l'Eq. (2.45) sont :

$$g_1(y) = \tanh(a_1 u) \quad (2.47)$$

$$g_2(y) = u \times \exp(-u^2/2) \quad (2.48)$$

où  $1 \leq a_1 \leq 2$  est une constante. Dans FastICA, la convergence signifie que le produit scalaire entre les vecteurs de poids actuel et ancien est presque égal à un et donc les valeurs des vecteurs de poids nouveau et ancien sont dans la même direction. Le maximum de l'approximation de la néguentropie de  $w^T X$  est calculé à un certain optimum de  $E[G(w^T X)]$ , où  $E[G(w^T X)^2] = \|w^2\| = 1$ . La solution optimale est obtenue où  $E[Xg(w^T X)] - \beta w = 0$ , et cette équation peut être résolue en utilisant la méthode de Newton. Soit  $F(w) = E[Xg(w^T X)] - \beta w$  ; par conséquent, la matrice Jacobienne est donnée par:

$$JF(w) = \frac{\partial F}{\partial w} = E[XX^T g'(w^T X)] - \beta I \quad (2.49)$$

Puisque les données sont blanchies; Donc,  $E[XX^T g'(w^T X)] \approx E[XX^T]E[g'(w^T X)] \Rightarrow E[XX^T g'(w^T X)] \approx E[g'(w^T X)]I$ , et par conséquent la matrice Jacobienne devient diagonale, ce qui est facilement inversé. La valeur de  $w$  peut être mise à jour selon la méthode de Newton comme suit [80]:

$$w^+ = \frac{F(w)}{F'(w)} = w - \frac{E[Xg(w^T X)] - \beta w}{E[g'(w^T X)] - \beta} \quad (2.50)$$

Éq. (2.50) peut être encore simplifié en multipliant les deux côtés par  $\beta - E[g'(w^T X)]$  comme suit [80]:


$$w^+ = E[Xg(w^T X)] - E[g'(w^T X)]w \quad (2.51)$$

Plusieurs unités de FastICA peuvent être utilisées pour extraire plusieurs composants indépendants, la sortie  $w_i^T X$  est décorrélée itérativement avec les autres sorties qui ont été calculées dans les itérations précédentes ( $w_1^T X, w_2^T X, \dots, w_{i-1}^T X$ ). Cette étape de décorrélation empêche différents vecteurs de converger vers les mêmes optima. La méthode d'orthogonalisation de déflation est similaire à la poursuite de projection, où les composantes indépendantes sont estimées une par une. Pour chaque itération, les projections des vecteurs de poids précédemment estimés  $(w_p w_j) w_j$  sont soustraites de  $w_p$ , où  $j = 1, 2, \dots, p - 1$ , puis  $w_p$  est normalisé comme dans l'équation (2.52) [80]. Dans cette méthode, les erreurs d'estimation dans les premiers vecteurs sont cumulées sur les suivants par orthogonalisation. La méthode d'orthogonalisation symétrique peut être utilisée lorsqu'une corrélation symétrique, c'est-à-dire qu'aucun vecteur n'est privilégié par rapport aux autres, est requise. Ainsi, les vecteurs  $w_i$  peuvent être estimés en parallèle ce qui permet un calcul parallèle. Cette méthode calcule tous les vecteurs  $w_i$  en utilisant un algorithme à une unité en parallèle, puis l'étape d'orthogonalisation est appliquée pour tous les vecteurs en utilisant la méthode symétrique comme suit,  $w = (w w^T)^{-\frac{1}{2}} w$  [80], où  $(w w^T)^{-\frac{1}{2}}$  est calculé à partir de la décomposition des valeurs propres comme suit,  $V(w w^T) = \lambda V$  ; ainsi,  $(w w^T)^{-\frac{1}{2}} = V^T \lambda^{-\frac{1}{2}} V$ .

$$\begin{cases} w_p = w_p - \sum_{j=1}^p w_p^T w_j w_j \\ w_p = \frac{w_p}{\sqrt{w_p^T w_p}} \end{cases} \quad (2.52)$$

## 2.2. Sélection de caractéristiques

Le nom de la sélection de caractéristiques dans l'apprentissage automatique, connu sous le nom de sélection de sous-ensembles de variables, est la sélection d'un sous-ensemble de variables pertinentes à utiliser dans la construction de modèles (classification ou régression) [86, 87] (comme le montre la figure 2.9).



Sélection de caractéristiques  
**Figure 2.9.** Réduction de dimensionnalité basée sur de la sélection des caractéristiques.

De nombreuses techniques sont utilisées pour sélectionner des caractéristiques [63]. L'une des techniques les plus populaires est le coefficient de corrélation entre les variables [88, 89].

- **Sélection de la caractéristique de corrélation**

La mesure de sélection de caractéristiques de corrélation (correlation feature selection (CFS)) évalue des sous-ensembles de caractéristiques sur la base de l'hypothèse suivante : « Les bons sous-ensembles de caractéristiques contiennent des caractéristiques fortement corrélées avec la classification, mais non corrélées les unes aux autres ». L'équation suivante donne le mérite d'un sous-ensemble de caractéristiques  $S$  composé de  $k$  caractéristiques [90]:

$$Merit_{S_k} = \frac{k\overline{r_{cf}}}{\sqrt{k+k(k-1)\overline{r_{ff}}}} \quad (2.53)$$

Ici,  $\overline{r_{cf}}$  est la valeur moyenne de toutes les corrélations de classification de caractéristiques, et  $\overline{r_{ff}}$  est la valeur moyenne de toutes les corrélations de caractéristiques. Le critère CFS est défini comme suit [90]:

$$CFS = \max_{S_k} \left[ \frac{r_{cf_1} + r_{cf_2} + \dots + r_{cf_k}}{\sqrt{k+2(r_{f_1f_2} + \dots + r_{f_1f_j} + \dots + r_{f_kf_{k-1}})}} \right] \quad (2.54)$$

Les variables  $r_{cf_i}$  et  $r_{f_if_j}$  sont appelées corrélations, mais ne sont pas nécessairement le coefficient de corrélation de Pearson ou le de Spearman.

Soit  $x_i$  la fonction d'indicateur d'appartenance définie pour la caractéristique  $f_i$ ; Alors l'équation (2.54) peut être réécrite comme un problème d'optimisation [90]:

$$CFS = \max_{x \in \{0,1\}^n} \left[ \frac{(\sum_{i=1}^n a_i x_i)^2}{\sum_{i=1}^n x_i + \sum_{i \neq j} 2b_{ij} x_i x_j} \right] \quad (2.55)$$

## Conclusion

Dans ce chapitre, le problème d'avoir un grand nombre de dimensions dans l'espace des caractéristiques connu sous le nom de malédiction dimensionnelle et son impact sur les modèles d'apprentissage automatique a été présenté. Les différentes méthodes de réduction des dimensions ont également été introduites. Dans ce contexte, les méthodes les plus utilisées pour l'extraction de caractéristiques ont été présentées, à savoir les techniques PCA, LDA et

ICA. Un aperçu a également été donné sur le processus de sélection des caractéristiques et la méthode la plus utilisée représentée dans la technique de corrélation entre les variables.

Le chapitre suivant fera l'objet de l'application des techniques de l'intelligence artificielle récentes basées sur l'apprentissage automatique de données réduites, comme étant la meilleure solution de surveillance de la qualité de l'eau par reconnaissance de formes dans un but de classification de données.

## *Chapitre III*

# **METHODES D'APPRENTISSAGE AUTOMATIQUE**

### **Introduction**

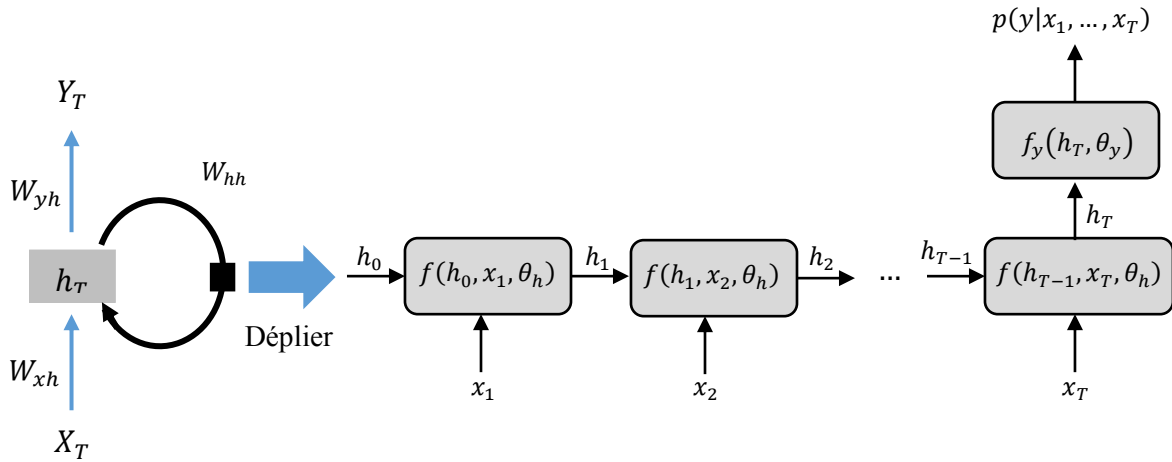
Actuellement, la construction des modèles fiables et de haute précision basés sur des techniques d'apprentissage automatique est une alternative prometteuse à la surveillance de la qualité de l'eau en temps réel. Le problème typique relié à l'apprentissage automatique réside dans lequel, les données générées par une distribution de probabilité (phénomène physique), sont divisées en plusieurs catégories dans le cas de la classification multi-classe de données. Dans cette étude, nous voulons construire un modèle permettant de classer de nouveaux points tirés selon la même distribution en se basant sur des méthodes d'apprentissage automatique et en utilisant une base de données limitée. La surveillance de la qualité de l'eau est un problème d'apprentissage supervisé des données pour définir l'état de l'eau à partir de ces données relatives à la qualité de l'eau à traiter. Pour traiter un tel problème de surveillance, plusieurs techniques ont été utilisées, on trouve spécialement les réseaux de neurones récurrents de type Long Short Term Memory (LSTM RNNs), les machines à vecteurs de support (SVM) et la machine d'apprentissage extrême (ELM).

Dans ce chapitre, les méthodes d'apprentissage automatique supervisé les plus importantes appliquées aux problèmes de classification sont présentées. Dans un premier temps, le concept de réseaux de neurones récurrents est rappelé et sa structure et ses caractéristiques générales sont décrites. Le principe général de la technique SVM appliquée aux problèmes de classification binaire et multi-classe, est également décrit. Enfin, l'une des méthodes d'apprentissage automatique les plus populaires est introduites, qui est la machine d'apprentissage extrême.

### **1. Réseau de neurones récurrents**

Réseau de neurones récurrents (RNNs) est un réseau de neurones conçu pour analyser les flux de données au moyen d'unités cachées. Dans certaines des applications telles que le

traitement du texte, la reconnaissance vocale et les séquences d'ADN, la sortie dépend des calculs précédents [91]. Étant donné que les RNN traitent des données séquentielles, ils conviennent bien au domaine de la surveillance de l'environnement où des quantités énormes de données séquentielles sont disponibles pour traiter. Les RNN peuvent également effectuer la tâche de classification pour chaque élément d'une séquence temporelle, la sortie dépendant des calculs précédents [92]. La figure 3.1 illustre l'architecture RNN standard et une structure dépliée avec T pas de temps.



**Figure 3.1.** Architecture RNN standard et structure dépliée avec T pas de temps. La fonction  $f$  et ses paramètres  $\theta_h$  sont partagés dans le temps.

Comme le montre la figure 3.1, la structure de RNN comprend la couche d'entrée, la couche cachée et la couche de sortie. Les nœuds de la couche cachée sont entièrement connectés, la sortie de la couche cachée devient également l'entrée de la couche cachée la prochaine fois.  $X_T$  est l'entrée au  $t^{\text{ème}}$  instant.  $Y_T$  est la sortie au  $t^{\text{ème}}$  instant.  $h_T$  est l'état de la couche cachée au  $t^{\text{ème}}$  instant.  $W_{xh}$  est le poids entre la couche d'entrée et la couche cachée,  $W_{yh}$  est le poids entre la couche cachée et la couche de sortie,  $W_{hh}$  est le poids entre la couche cachée actuelle et la couche cachée à la prochaine fois.

En théorie, RNN est censé porter l'information dans le temps. Cependant, il est assez difficile de propager toutes ces informations lorsque le pas de temps est trop long. Lorsqu'un réseau a trop de couches profondes, il devient impossible à entraîner [93]. Ce problème est appelé: problème de disparition du gradient [94]. Le réseau de neurones met à jour le poids à l'aide de l'algorithme de descente de gradient [93, 95]. Les gradients diminuent lorsque le

réseau progresse vers les couches inférieures. Si le gradient reste constant, cela signifie qu'il n'y a pas d'amélioration. Le modèle apprend du changement de gradient, ce changement affecte la sortie du réseau. Cependant, si la différence de gradient est très faible (c'est-à-dire que les poids changent un peu), le réseau ne pourra rien apprendre [93].

- **Le problème de disparition du gradient**

Considérons la figure 3.1, ainsi qu'une perte  $f_l(h_T, \theta_y)$  qui est calculée directement à partir de  $h_T$  (sous laquelle  $f_y(h_T, \theta_y)$  et  $p(y|x_1, \dots, x_T)$  sont calculés implicitement). Supposons que nous soyons intéressés à obtenir les gradients par rapport à  $\theta$ , les paramètres appartenant au RNN lui-même (comme sur la figure). En utilisant la règle de la chaîne ordinaire, nous pouvons écrire le Jacobien (ou gradient transposé) comme [96]:

$$\frac{\partial^+ f_l}{\partial \theta} = \frac{\partial f_l}{\partial h_T} \frac{\partial^+ h_T}{\partial \theta} \quad (3.1)$$

car  $\frac{\partial^+ \theta_y}{\partial \theta} = 0$ . Maintenant, en appliquant la règle de la chaîne pour les dérivées ordonnées à  $\frac{\partial^+ h_T}{\partial \theta}$  avec  $v_1 = \theta, v_2 = h_0, v_3 = x_1, v_4 = h_1, \dots$  donne immédiatement [96]:

$$\frac{\partial^+ h_T}{\partial \theta} = \frac{\partial^+ h_T}{\partial h_T} \frac{\partial h_T}{\partial \theta} + \frac{\partial^+ h_T}{\partial h_{T-1}} \frac{\partial h_{T-1}}{\partial \theta} + \frac{\partial^+ h_T}{\partial x_{T-1}} \frac{\partial x_{T-1}}{\partial \theta} + \frac{\partial^+ h_T}{\partial h_{T-2}} \frac{\partial h_{T-2}}{\partial \theta} + \dots \quad (3.2)$$

Enfin, remarquant que  $\frac{\partial x_t}{\partial \theta} = 0$  pour tout  $t$  et que  $\frac{\partial h_0}{\partial \theta} = 0$ , on a [96]:

$$\frac{\partial^+ h_T}{\partial \theta} = \sum_{\tau=0}^{T-1} \frac{\partial^+ h_T}{\partial h_{T-\tau}} \frac{\partial h_{T-\tau}}{\partial \theta} \quad (3.3)$$

Cette décomposition divise  $\frac{\partial^+ h_T}{\partial \theta}$  en ses composantes temporelles, ce qui montre clairement que la norme spectrale de  $\frac{\partial^+ h_T}{\partial h_{T-\tau}}$  joue un rôle majeur dans la façon dont  $h_{T-\tau}$  affecte le gradient final  $\frac{\partial^+ f_l}{\partial \theta}$ . En particulier, si la norme spectrale de  $\frac{\partial^+ h_T}{\partial h_{T-\tau}}$  est extrêmement petite, alors  $h_{T-\tau}$  a un effet négligeable sur le gradient final, ce qui rend extrêmement difficile l'apprentissage des événements survenus au temps  $T - \tau$  [96].

La dernière étape consiste à considérer  $\frac{\partial^+ h_T}{\partial h_{T-\tau}}$  plus en détail. Notez que, pour les RNN simples, il existe exactement un chemin de  $h_{T-\tau}$  à  $h_T$  (voir figure 3.1), et cela correspond à une seule composante de gradient [96]:

$$\frac{\partial^+ h_T}{\partial h_{T-\tau}} = \frac{\partial h_T}{\partial h_{T-1}} \frac{\partial h_{T-1}}{\partial h_{T-2}} \cdots \frac{\partial h_{T-\tau+1}}{\partial h_{T-\tau}} \quad (3.4)$$

et donc, en termes de norme spectrale, nous avons [96]:

$$\left\| \frac{\partial^+ h_T}{\partial h_{T-\tau}} \right\| \leq \left\| \frac{\partial h_T}{\partial h_{T-1}} \right\| \left\| \frac{\partial h_{T-1}}{\partial h_{T-2}} \right\| \cdots \left\| \frac{\partial h_{T-\tau+1}}{\partial h_{T-\tau}} \right\| \quad (3.5)$$

Dans le cas des RNN simples, chaque partiel est le produit de deux Jacobiens, l'un correspondant à  $\tanh$  (qui est diagonal) et l'autre correspondant à la multiplication matricielle (qui est  $W_{hh}$ ) ; et cela signifie à son tour que les normes spectrales associées à ces partiels peuvent varier considérablement au cours de la formation. En particulier, nous pouvons voir que si la plus grande norme spectrale de tout partiel est  $\alpha < 1$ , alors nous avons  $\left\| \frac{\partial^+ h_T}{\partial h_{T-\tau}} \right\| \leq \alpha^\tau$ , et donc la contribution aux gradients des événements au temps  $T - \tau$  diminue exponentiellement rapidement avec  $\tau$ . De nombreuses tentatives ont été faites pour atténuer ce problème, par exemple en régularisant directement les normes [97], en initialisant ou en restreignant les matrices de poids à être orthogonales [98], ou en incluant des connexions directes entre des états cachés non adjacents. Cependant, l'architecture qui a remporté un grand succès est la Long Short Term Memory [99], qui introduit des chemins supplémentaires entre  $h_{T-\tau}$  et  $h_T$  qui sont associés à des normes spectrales plus stables.

### 1.1. Long Short Term Memory (LSTM)

Pour surmonter ce problème, Sepp et Schmidhuber [99], ont amélioré les RNN en créant une architecture appelée Long Short Term Memory (LSTM). Le réseau utilise une meilleure structure pour identifier et transmettre les informations ultérieurement [100]. Un schéma d'une unité de LSTM RNN utilisés dans ce travail peut être vu sur la figure 3.2.

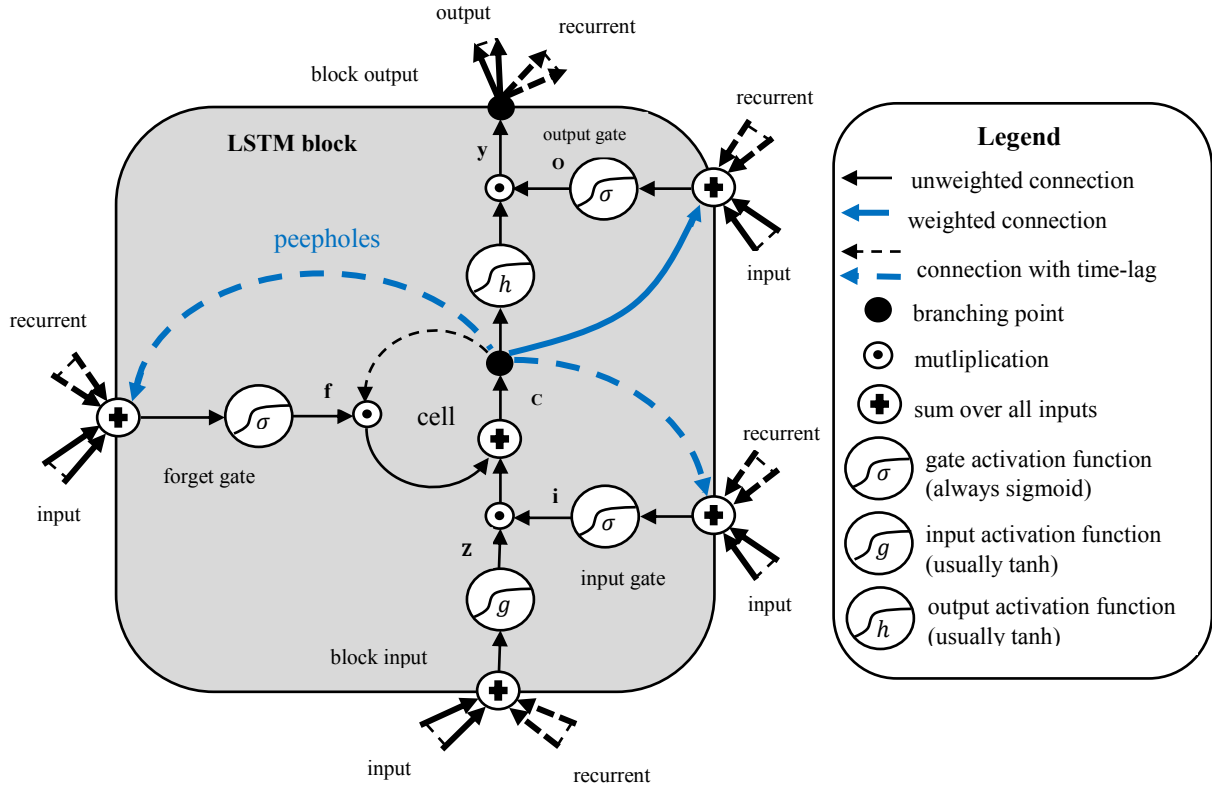


Figure 3.2. Architecture LSTM RNN [101].

$$f_t = \sigma(W_f \cdot [C_{t-1}, y_{t-1}, x_t] + b_f) \quad (3.6)$$

$$i_t = \sigma(W_i \cdot [C_{t-1}, y_{t-1}, x_t] + b_i) \quad (3.7)$$

$$O_t = \sigma(W_o \cdot [C_{t-1}, y_{t-1}, x_t] + b_o) \quad (3.8)$$

$$C_t = f_t * C_{t-1} + i_t * Z \quad (3.9)$$

$$Z = \tanh(W_c \cdot [y_{t-1}, x_t] + b_c) \quad (3.10)$$

$$y_t = O_t * \tanh(C_t) \quad (3.11)$$

où  $x_t$  est le vecteur d'entrée,  $y_t$  est l'état des unités de sortie,  $C_t$  est le vecteur d'état de la cellule,  $W$  et  $b$  sont des matrices de paramètres et un vecteur,  $f_t$ ,  $i_t$  et  $O_t$  sont des vecteurs de porte d'oubli, de porte d'entrée et de porte de sortie, respectivement.  $\sigma$  est une fonction sigmoïde et  $\tanh$  est une fonction sigmoïde logistique de remise à l'échelle comprise entre  $-1$  et  $1$  [102].

## 2. Machines à vecteurs de support (SVM)

### 2.1. SVM binaire

Le concept clé des SVM, qui ont été initialement développés pour des problèmes de classification binaire, est l'utilisation d'hyperplans pour définir des limites de décision séparant les points de données de différentes classes [103]. Les SVM sont capables de gérer à la fois des tâches de classification simples et linéaires, ainsi que des problèmes de classification plus complexes, c'est-à-dire non linéaires. Les problèmes séparables et non séparables sont traités par les SVM dans le cas linéaire et non linéaire. L'idée derrière les SVM est de mapper les points de données d'origine de l'espace d'entrée à un espace de caractéristiques de grande dimension, voire de dimension infinie, de sorte que le problème de classification devienne plus simple dans l'espace de caractéristiques [103]. Le mappage se fait par un choix approprié d'une fonction noyau.

Étant donné l'entrée de données  $x_i$  ( $i = 1, 2, \dots, N$ ),  $N$  est le nombre d'échantillons. Les échantillons sont supposés avoir deux classes, à savoir la classe positive et la classe négative. Chacune des classes associées aux étiquettes soit  $y_i = 1$  pour la classe positive et  $y_i = -1$  pour la classe négative, respectivement. Dans le cas de données linéaires, il est possible de déterminer l'hyperplan  $f(x) = 0$  qui sépare les données [59, 104]:

$$f(x) = w^T x + b = \sum_{i=1}^N w_i x_i + b \quad (3.12)$$

où  $w$  est un vecteur de dimension  $N$  et  $b$  est un scalaire. Le vecteur  $w$  et le scalaire  $b$  sont utilisés pour définir la position de l'hyperplan séparateur. La fonction de décision est effectuée en utilisant le *signe*  $f(x)$  pour créer un hyperplan de séparation qui classe les données d'entrée dans une classe positive ou négative.


Un hyperplan distinctement séparatif doit satisfaire les contraintes [59, 104]:

$$f(x_i) = \begin{cases} 1, & \text{if } y_i = 1 \\ -1, & \text{if } y_i = -1 \end{cases} \quad (3.13)$$

ou il peut être présenté dans l'équation complète [59]:

$$y_i f(x_i) = y_i (w^T x_i + b) \geq 1, \quad \text{for } i = 1, 2, \dots, N \quad (3.14)$$

L'hyperplan séparateur qui crée la distance maximale entre le plan et les données les plus proches, c'est-à-dire la marge maximale, est appelé hyperplan séparateur optimal. Un exemple de l'hyperplan optimal de deux ensembles de données est présenté sur la figure 3.3.



**Figure 3.3.** La structure SVM de base.

Dans la figure 3.3, une série de points de données pour deux classes de données différentes sont représentées, les carrés pour la classe positive et les cercles pour la classe négative. Les SVM essaient de placer une frontière linéaire entre les deux classes différentes et de l'orienter de manière à maximiser la marge représentée par la ligne pointillée. De plus, les SVM tentent d'orienter la frontière pour s'assurer que la distance entre la frontière et le point de données le plus proche dans chaque classe est maximale. Ensuite, la frontière est placée au milieu de cette marge entre deux points. Les points de données les plus proches utilisés pour définir la marge sont appelés vecteurs de support, représentés par les cercles et les carrés gris. Lorsque les vecteurs de support ont été sélectionnés, le reste de l'ensemble de caractéristiques n'est pas requis, car les vecteurs de support peuvent contenir toutes les informations nécessaires pour définir le classificateur. D'après la géométrie, la marge géométrique est  $\|W\|^{-2}$  [59].

Compte tenu du bruit avec les variables d'écart  $\xi_i$  et de la pénalité d'erreur  $C$ , l'hyperplan optimal séparant les données peut être obtenu comme solution au problème d'optimisation suivant [59, 105]:

$$\text{Min}_{w,b,\xi} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi_i \quad (3.15)$$

sujet à

$$\begin{cases} y_i(w^T x_i + b) \geq 1 - \xi_i, & i = 1, \dots, M \\ \xi_i \geq 0, & i = 1, \dots, M \end{cases} \quad (3.16)$$

où  $\xi_i$  mesure la distance entre la marge et les exemples  $x_i$  qui se trouvent du mauvais côté de la marge. Le calcul peut être simplifié en convertissant le problème avec la condition de Kuhn-Tucker en le problème dual lagrangien équivalent, qui sera [59]:

$$\text{Min} \quad L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^M \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^M \alpha_i \quad (3.17)$$

La tâche consiste à minimiser l'équation (3.17) par rapport à  $w$  et  $b$ , tout en exigeant que les dérivées de  $L$  à  $\alpha$  disparaissent. Au point optimal, nous avons les équations de point-selle suivantes [59]:

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0, \quad \frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad (3.18)$$

qui remplacent en forme [59]:

$$\sum_{i=1}^M \alpha_i y_i = 0, \quad w = \sum_{i=1}^M \alpha_i y_i x_i \quad (3.19)$$

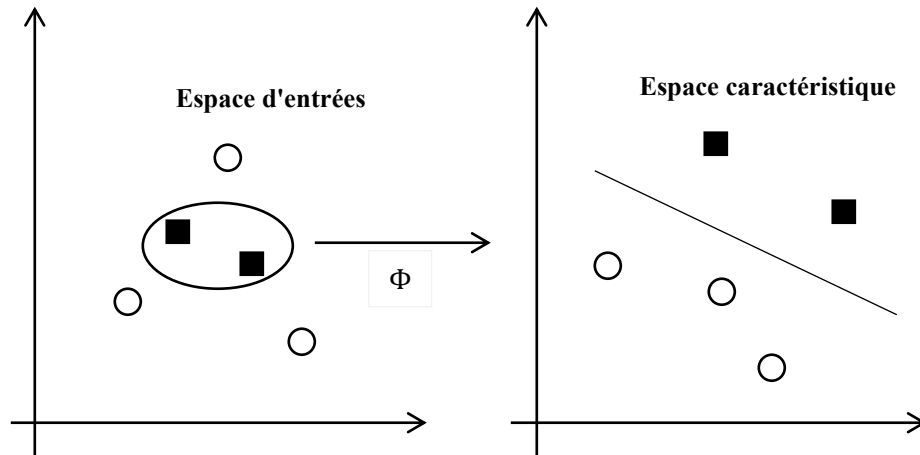
D'après l'équation (3.19), nous trouvons que  $w$  est contenu dans le sous-espace couvert par le  $x_i$ . En substituant l'équation (3.19) dans l'équation (3.17), on obtient le problème d'optimisation quadratique dual [59, 105]:

$$\begin{cases} \text{Max}_{\alpha_i} L(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \text{s. t.} \quad \sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C \end{cases} \quad (3.20)$$

Ainsi, en résolvant le problème d'optimisation dual, on obtient les coefficients  $\alpha_i$  qui sont nécessaires pour exprimer le  $w$  pour résoudre l'équation (3.15). Cela conduit à une fonction de décision non linéaire [59]:

$$f(x) = \text{sign} \left( \sum_{i,j=1}^M \alpha_i y_i (x_i x_j) + b \right) \quad (3.21)$$

Les SVM peuvent également être utilisées dans des tâches de classification non linéaire avec l'application de fonctions du noyau. Les données à classer sont mappées sur un espace de caractéristiques de grande dimension, où une classification linéaire est possible (figure 3.4).



**Figure 3.4.** Mapper les données d'apprentissage de manière non linéaire dans un espace de caractéristiques de dimension supérieure via  $\Phi$ , et construire un hyperplan de séparation avec une marge maximale.

En utilisant la fonction vectorielle non linéaire  $\Phi(x) = (\Phi_1(x), \dots, \Phi_l(x))$  pour mapper le vecteur d'entrée à  $n$  dimensions  $x$  sur l'espace des caractéristiques à  $l$  dimension, la fonction de décision linéaire sous forme duale est donnée par [59]:

$$f(x) = \text{sign} \left( \sum_{i,j=1}^M \alpha_i y_i (\Phi^T(x_i) \cdot \Phi(x_j)) + b \right) \quad (3.22)$$

Travailler dans l'espace des caractéristiques de grande dimension permet l'expression de fonctions complexes, mais génère également le problème. Le problème de calcul se produit en raison des grands vecteurs et le surajustement existe également en raison de la haute dimensionnalité. Ce dernier problème peut être résolu en utilisant la fonction kernel. Un noyau est une fonction qui renvoie un produit scalaire des mappages d'espace de caractéristiques des points de données d'origine, indiqué par  $K(x_i, x_j) = (\Phi^T(x_i) \cdot \Phi(x_j))$ . Lors de l'application d'une fonction noyau, l'apprentissage dans l'espace des fonctionnalités ne nécessite pas d'évaluation explicite de  $\Phi$  et la fonction de décision sera [59, 106]:

$$f(x) = \text{sign} \left( \sum_{i,j=1}^M \alpha_i y_i K(x_i, x_j) + b \right) \quad (3.23)$$

Toute fonction qui satisfait le théorème de Mercer peut être utilisée comme fonction noyau pour calculer un produit scalaire dans l'espace des caractéristiques [59]. Il existe différentes fonctions du noyau utilisées dans SVM telles que [103, 106]:

Noyau linéaire :

$$K(x_i, x_j) = x_i^T \cdot x_j \quad (3.24)$$

Fonction polynomiale:

$$K(x_i, x_j) = (\gamma x_i^T \cdot x_j + r)^d \quad (3.25)$$

Fonction de base radiale (RBF) :

$$K(x_i, x_j) = \exp \left( -\frac{\|x_i - x_j\|^2}{2\gamma^2} \right) \quad (3.26)$$

Noyau sigmoïde :

$$K(x_i, x_j) = \tanh\{\gamma x_i^T \cdot x_j + r\} \quad (3.27)$$

où  $d, r \in \mathbb{N}$  et  $\gamma \in \mathbb{R}^+$  sont des constantes.

## 2.2. SVM multi-classes

Les SVM sont dans leur origine binaire. Cependant, les problèmes du monde réel sont dans la plupart des cas multi-classes qui désigne une classification impliquant plus de deux classes différentes. Les méthodes de machines à vecteurs de support multiclassées réduisent le problème multiclassé à une composition de plusieurs hyperplans à deux classes permettant de tracer les frontières de décision entre les différentes classes. Ces méthodes décomposent l'ensemble d'exemples en plusieurs sous-ensembles, chacun représentant un problème de classification binaire. Pour chaque problème, un hyperplan séparateur est déterminé par la méthode SVM binaire. Lors de la classification, une hiérarchie d'hyperplans binaires est construite qui est parcourue de la racine à une feuille pour décider de la classe d'un nouvel exemple. Dans le cadre multi-classes, deux approches sont les plus utilisées, on trouve : « un contre tous » et « un contre un » [107, 108].

### a. Un contre tous

La première implémentation utilisée pour la classification multiclassée SVM est la méthode un contre tous. Il construit  $k$  modèles SVM où  $k$  est le nombre de classes. Le  $i^{\text{ème}}$  SVM est entraîné avec tous les exemples de la  $i^{\text{ème}}$  classe avec des étiquettes positives et tous les autres exemples avec des étiquettes négatives. Ainsi étant donné  $l$  données d'apprentissage  $(x_1, y_1), \dots, (x_l, y_l)$ , où  $x_i \in \mathbb{R}^n, i = 1, \dots, l$  et  $y_i \in \{1, \dots, k\}$  est la classe de  $x_i$ , le  $i^{\text{ème}}$  SVM résout le problème suivant [107, 108]:


$$\text{Min}_{w^i, b^i, \xi^i} \frac{1}{2} \|w^i\|^2 + C \sum_{i=1}^N \xi_j^i (w^i)^T \quad (3.28)$$

sujet à

$$\begin{cases} (w^i)^T \phi(x_j) + b^i \geq 1 - \xi_j^i, & \text{if } y_j = i, \\ (w^i)^T \phi(x_j) + b^i \leq 1 - \xi_j^i, & \text{if } y_j \neq i, \\ \xi_j^i \geq 0, & j = 1, \dots, N, \end{cases} \quad (3.29)$$

où les données d'apprentissage  $x_i$  sont mappées à un espace de dimension supérieure par la fonction  $\phi$  et  $C$  est le paramètre de pénalité.

Minimiser l'équation (3.28) signifie que nous aimerions maximiser  $\frac{2}{\|w_i\|}$ , la marge entre deux groupes de données. Lorsque les données ne sont pas séparables, il existe un terme de pénalité  $C \sum_{i=1}^l \xi_j^i$  qui peut réduire le nombre d'erreurs d'apprentissage. L'architecture de classification selon l'approche *un contre tous* est montrée dans la figure 3.5.



**Figure 3.5.** Architecture de classification selon l'approche un contre tous [14].

### b. Un contre un

Cette méthode construit  $\frac{k(k-1)}{2}$  classificateurs où chacun est entraîné sur les données de deux classes. Pour les données d'apprentissage des  $i^{\text{ème}}$  et  $j^{\text{ème}}$  classes, nous résolvons le problème de classification binaire suivant [107, 108]:

$$\text{Min}_{w^{ij}, b^{ij}, \xi^{ij}} \frac{1}{2} \|w^{ij}\|^2 + C \sum_t \xi_t^{ij} (w^{ij})^T \quad (3.30)$$

sujet à

$$\begin{cases} (w^{ij})^T \phi(x_t) + b^{ij} \geq 1 - \xi_t^{ij}, & \text{if } y_t = i, \\ (w^{ij})^T \phi(x_t) + b^{ij} \leq -1 + \xi_t^{ij}, & \text{if } y_t \neq i, \\ \xi_t^{ij} \geq 0, & j = 1, \dots, N, \end{cases} \quad (3.31)$$

Il existe différentes méthodes pour effectuer les futurs tests une fois que tous les classificateurs  $\frac{k(k-1)}{2}$  sont construits. Après quelques tests, la décision est prise en utilisant la stratégie suivante : si le *signe*  $(w^{ij})^T \phi(x_t) + b^{ij}$  indique que  $x$  est dans la  $i^{\text{ème}}$  classe, alors le vote pour la  $i^{\text{ème}}$  classe est ajouté par un. Sinon, le  $j^{\text{ème}}$  est augmenté de un. Ensuite,  $x$  est prédit dans la classe utilisant le plus grand vote. L'architecture de classification selon l'approche *un contre tous* est montrée dans la figure 3.6.

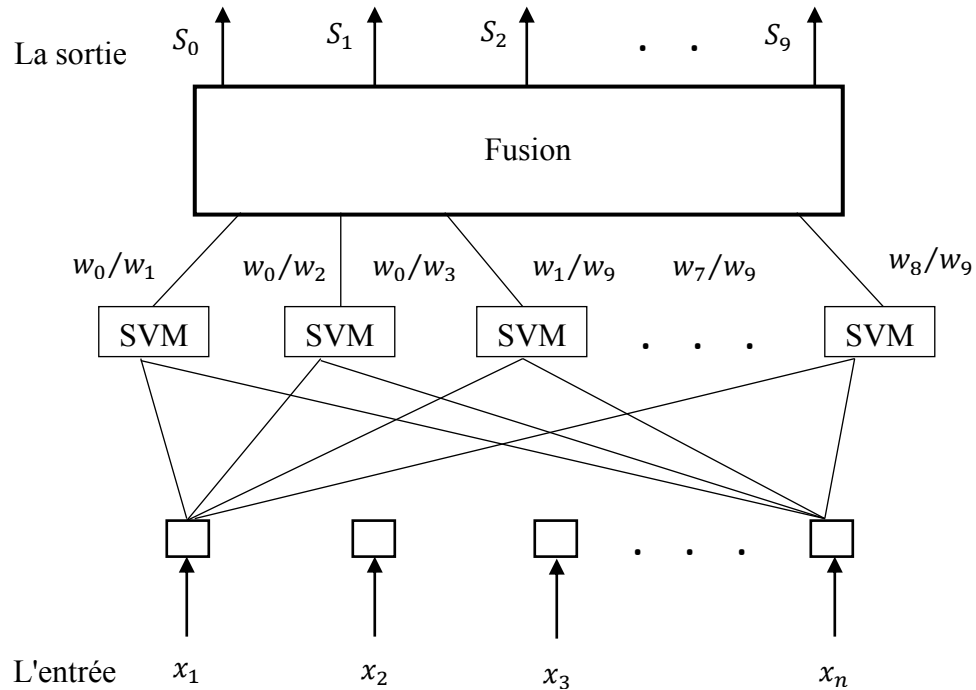


Figure 3.6. Architecture de classification selon l'approche un contre un [14].

### 3. Machine d'apprentissage extrême

La machine d'apprentissage extrême (ELM) est un nouveau type de réseau de neurones avec une seule couche de nœuds cachés (SLFN : single layer feedforward neural network) (comme le montre la figure 3.7), où les paramètres, y compris les poids d'entrée, sont générés de manière aléatoire et jamais mis à jour, ainsi, de bonnes performances de généralisation et

une vitesse d'apprentissage élevée sont obtenus. L'algorithme ELM a été appliqué avec succès dans plusieurs domaines tels que la classification, la régression, la reconnaissance de formes et le traitement d'images [109]. Dans cette étude, un bref résumé de l'ELM est présenté.

Soit  $N$  le nombre d'échantillons de données d'apprentissage  $(x_i, t_i)$ , où  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$  et  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$ , et  $\tilde{N}$  le nombre de nœuds cachés, chacun avec une fonction d'activation  $g(x)$ . Pour chaque échantillon  $j$ , la sortie  $o_j$  est exprimée sous la forme [109, 110] :

$$o_j = \sum_{i=1}^{\tilde{N}} \beta_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i g_i(w_i \cdot x_j + b_i), j = 1, 2, \dots, N \quad (3.32)$$

où  $w_i = [w_{i1}, w_{i2}, \dots, w_{i\tilde{N}}]^T$  est le vecteur de poids reliant les nœuds de la couche d'entrée et le  $i^{\text{ème}}$  nœud caché,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  est le vecteur de poids reliant les nœuds de la couche de sortie et le  $i^{\text{ème}}$  nœud caché, et  $b_i$  représente le biais du  $i^{\text{ème}}$  nœud caché.

L'équation (3.32) peut être réécrite sous forme matricielle comme suit [111] :

$$\beta H = T \quad (3.33)$$

Où :

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (3.34)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad (3.35)$$

Dans le cas de  $\tilde{N} \ll N$ ,  $\beta$  ne peut pas être calculé par l'inversion de matrice directe. Par conséquent, la solution des moindres carrés de la plus petite norme est calculée [111] :

$$\hat{\beta} = H^\dagger T \quad (3.36)$$

où  $H^\dagger$  est l'inverse généralisé de Moore-Penrose de la matrice  $H$  [111]. Selon la théorie de Bartlett [112], les performances de généralisation de SLFN seront améliorées en minimisant les erreurs d'apprentissage ainsi que la norme des poids de sortie, et la solution  $\hat{\beta}$  peut garantir la capacité de généralisation de SLFN dans la théorie.

En général, le fonctionnement de l'algorithme ELM peut se résumer aux trois étapes suivantes [111] :

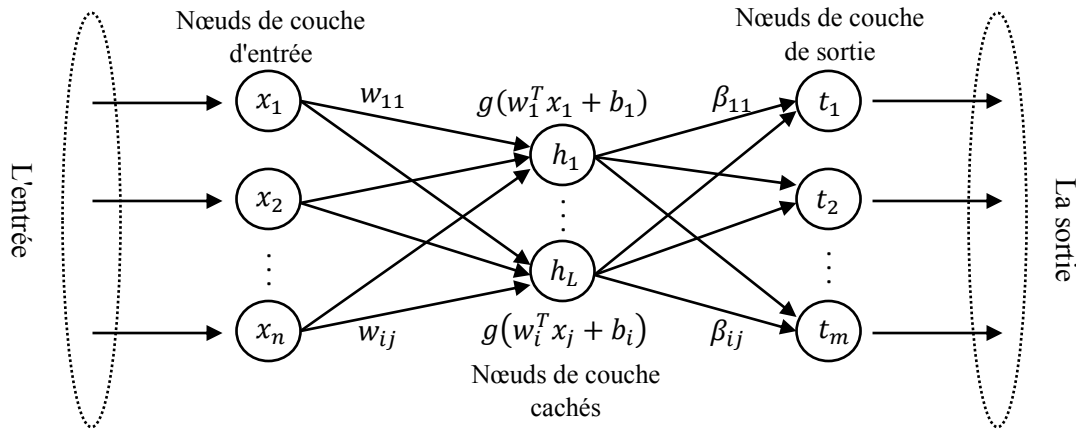
*Étape (1).* Attribuer au hasard des valeurs pour le poids d'entrée  $w_i$  et le biais  $b_i$ .

*Étape (2).* Calculer la matrice de sortie  $H$  de la couche cachée.

*Étape (3).* Calculer les poids de sortie  $\hat{\beta} = H^\dagger T$ .

Enfin, la sortie de l'ELM peut être calculée comme suit :

$$o_j = \sum_{i=1}^{\tilde{N}} \hat{\beta}_i g_i(w_i \cdot x_j + b_i) \quad (3.37)$$



**Figure 3.7.** La structure de base de l'ELM.

## Conclusion

Dans ce chapitre, les méthodes d'apprentissage automatique supervisé les plus importantes appliquées aux problèmes de classification ont été présentées. Le concept de réseaux de neurones récurrents a été rappelé et sa structure et ses caractéristiques générales ont été

décrites. Ensuite, le principe de la technique SVM appliquée à la classification binaire et multi-classes a été décrit. Enfin, un bref a été donné sur la machine d'apprentissage extrême. Le chapitre suivant est attribué à la simulation, où la mise en œuvres et l'évaluation des performances des techniques étudiées est comparée et évaluée en fonction de la norme de précision appliquées au domaine de l'eau.

## *Chapitre IV*

# **SIMULATION ET EVALUATION**

### **Introduction**

Le quatrième et dernier chapitre est dédié à la simulation et la validation des techniques proposées et étudiées comme solution pour la surveillance intelligente de la qualité de l'eau par classification. L'objectif est donc l'évaluation des performances de chacune des techniques utilisées. Dans cette étude, l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) avec les LSTM RNN, SVM ou ELM est proposée pour effectuer la classification de la qualité de l'eau. Divers scénarios sont examinés à l'aide d'un ensemble de données réel de descripteurs d'eau, et les résultats sont comparés pour obtenir les meilleures performances du processus de classification et de surveillance.

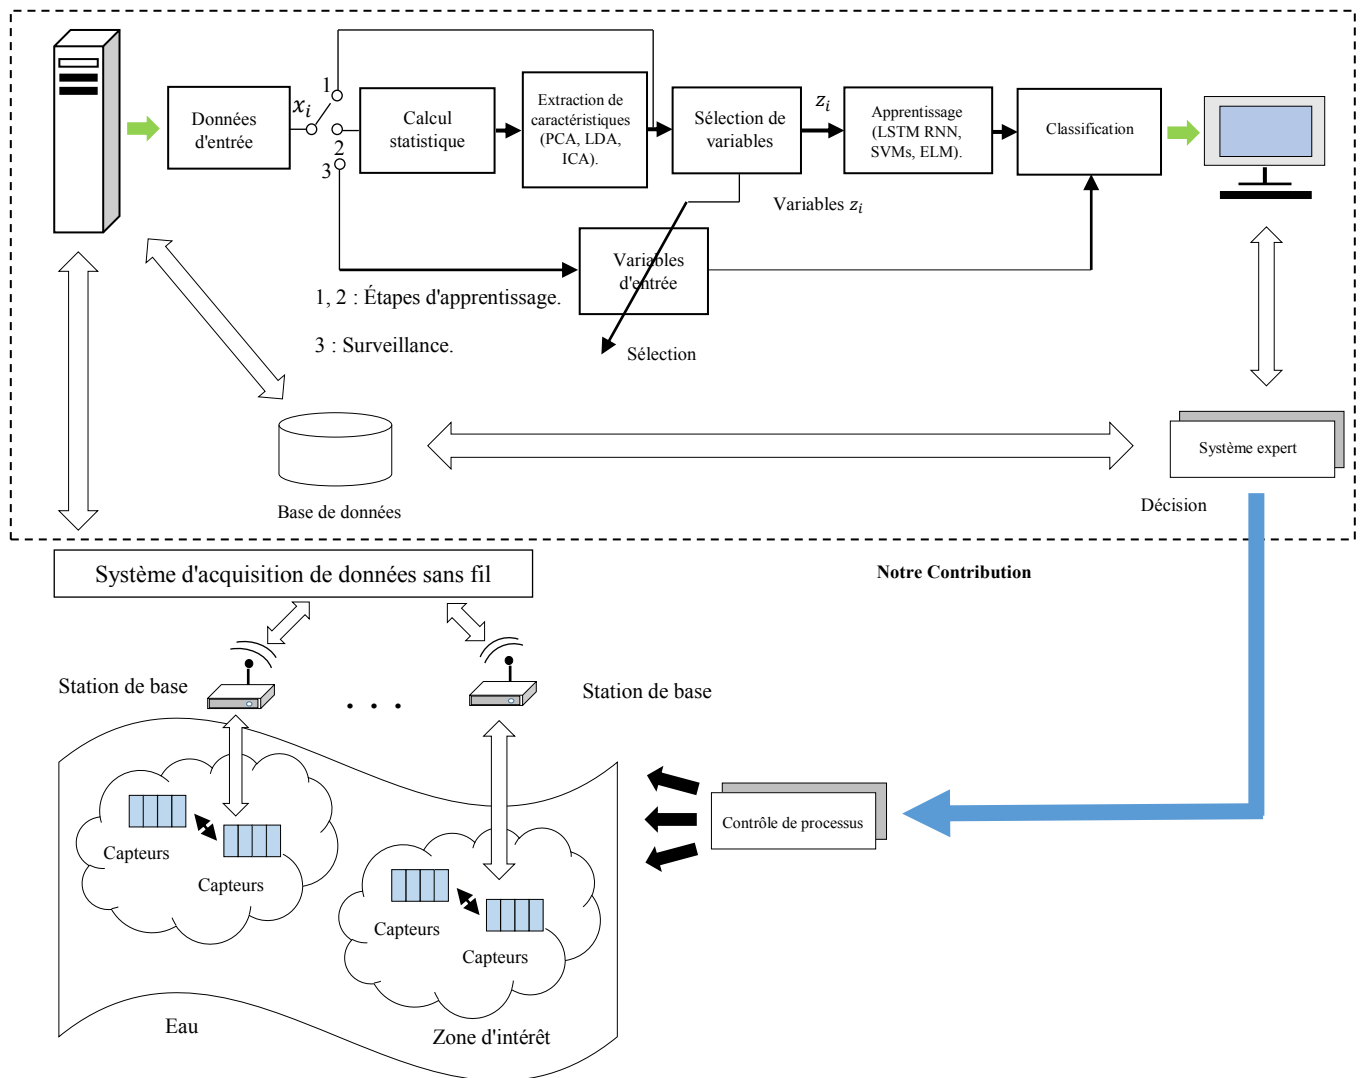
Dans ce dernier chapitre, la problématique de l'étude est d'abord présentée, où le système proposé est présenté, une brève description de la zone d'étude et de la base de données qui a été collectée est illustrée. Ensuite, les résultats de l'extraction et de la sélection de caractéristiques à l'aide des techniques PCA, LDA, et ICA sont présentés et discutés. Une explication détaillée du processus d'apprentissage et de classification est également évaluée. Une étude comparative est effectuée, permettant de faire un choix décisif de la meilleure méthode qui répond à notre problématique posée sur les deux plans (réduction dimensionnelle et classification) on évaluera pour les méthodes exposées LSTM RNN, SVM et ELM à travers des résultats de classification liés aux mesures des paramètres tels que : le taux de classification et le temps d'apprentissage et de test. Une discussion générale des résultats conclura ce travail de simulation pour choisir le modèle de décision la mieux adaptée pour notre application.

### **1. Problématique**

#### **1.1. Le système de surveillance de la qualité de l'eau à multi-capteurs proposé**

Dans cette étude, la mesure, la surveillance et le contrôle de la qualité de l'eau peuvent être considérés comme un problème typique de reconnaissance de formes. Généralement, il

comprend l'acquisition de données, le traitement du signal, l'extraction et la sélection des caractéristiques, y compris la réduction de caractéristiques, la prise de décision concernant la qualité de l'eau et le contrôle de processus. Notre approche stratégique de surveillance de la qualité de l'eau proposée dans cette étude repose d'abord sur étape préliminaire de préparation de la base de données. Le processus de surveillance est donc vu comme un problème de reconnaissance de formes, où les classes correspondent à différents états qualitatifs de l'eau, et les formes représentent les mesures des paramètres descripteurs de l'eau.



**Figure 4.1.** Le système multi-capteurs de surveillance de la qualité de l'eau [14].

Le rôle des techniques de classification est de séparer les données en plusieurs classes distinctes utilisant trois techniques qui sont issues du domaine de l'intelligence artificielle

telles que, les LSTM RNN, les SVM et l'ELM. Des méthodes servant comme outils de base pour une possible intégration dans un système d'aide à la décision. L'architecture du système multi-capteurs de surveillance et de contrôle de la qualité de l'eau proposé est présentée dans la figure 4.1.

Au niveau du système de surveillance, les paramètres physico-chimiques utilisés peuvent être nombreux. Ces paramètres sont transformés en signaux électriques à partir des capteurs installés dans la station de production d'eau, et transmis vers une unité de traitement de données et de contrôle supervisée par un expert qui assure l'acquisition, l'analyse et la décision.

## 1.2. Description des données d'entrée

Le barrage de Tilesdit est situé géographiquement dans la commune de Bechloul, à 20 km au sud-est du département de Bouira (Algérie). Ce barrage est situé entre les coordonnées cartographiques et Lambert suivantes : Latitude : 35° 13' 22" Nord; Longitude : 4° 14' 23" Est (figure 4.2) [14]. Il est caractérisé par un climat semi-aride et une averse moyenne d'environ 440-660 mm/an. Le volume du réservoir de ce barrage à 167 millions de m<sup>3</sup>, est conçu pour contrôler la tension qui persiste dans la distribution de l'eau dans 12 communes (comme le montre la figure 4.3) [14]. Selon le département hydraulique de la wilaya de Bouira, le barrage de Tilesdit se caractérise par les données techniques suivantes : Longueur : 425 m, Largeur en crête : 10 m, et Hauteur : 65 m.



Fig. 4.2. Carte géographique situant le barrage « Tilesdit » [Google Maps].



**Fig. 4.3.** Image représentant le site du barrage « Tiledit » [Google Earth].

Dans cette étude, nous cherchons à mettre en œuvre notre approche de surveillance de la qualité des eaux de surface, en utilisant plusieurs paramètres physico-chimiques fournis par certains capteurs de mesure installés dans la station. Ces paramètres ont été collectés à partir de la station de production d'eau de Tiledit pendant trois ans (2016-2018). Notre connaissance du processus de traitement se limite aux données enregistrées à partir de cette station. Quelques paramètres de qualité des eaux de surface comme la température ( $T^\circ$ ), le pH, la conductivité électrique (EC) et la turbidité (TU) sont mesurés en continu chaque jour (3 fois/jour), en plus des mesures et des tests de quelques paramètres chimiques au niveau de laboratoire, tels que le magnésium (Mg), le bicarbonate (B), la dureté permanente (H) et l'alcaline à titre complet (FTA) qui sont effectués chaque semaine. Ces paramètres sont mesurés et à n'importe quel niveau du processus de traitement. Après avoir effectué les mesures, elles sont comparées aux normes de consommation spécifiées par l'Agence Nationale des Ressources Hydrauliques (ANRH) par un expert afin de déterminer la qualité de l'eau à produire.

L'ensemble de paramètres descripteurs collectés relatives aux caractéristiques physico-chimiques de l'eau est utilisé pour composer un modèle typique de classification permettant de distinguer trois états bien différents. Dans cette étude, les données mesurées ci-dessus sont utilisées pour analyser la relation entre ces paramètres et pour vérifier le modèle de surveillance de la qualité de l'eau pour la décision sur la qualité de l'eau. Les statistiques

descriptives de ces paramètres sélectionnés (paramètres physico-chimiques) sont présentées dans le Tableau 4.1.

**Tableau 4.1.** Statistiques descriptives des paramètres physico-chimiques.

Variables	Min	Max	Moyenne	Écart-type
pH	7,15	8,30	7,567	0,25
EC	414,00	624,00	585,393	36,278
T°	9,70	24,20	16,13	3,483
TU	1,320	23,81	3,835	2,392
Mg	7,290	47,628	22,268	4,931
B	158,620	289,14	222,497	23,213
H	0,00	168,00	32,287	23,029
FTA	130,00	237,00	181,845	18,703

## 2. Résultats et discussion

Dans cette étude, la décision sur la qualité de l'eau est évaluée en utilisant des méthodes de classification. La procédure de contrôle utilisé pour la surveillance de la qualité de l'eau est assurée par ces techniques de classification. Pour des raisons d'amélioration des performances, le traitement et l'analyse de données ont besoin d'un traitement statistique spécifique pour acquérir plus d'avantages et de garantir une bonne décision de la qualité de l'eau. A cet effet, l'extraction et la sélection de caractéristiques est une étape primordiale du processus de classification, préalable à l'étape de décision, qui permet à partir d'une grande base de données, de déterminer les variables pertinents par la réduction de la redondance entre variables ou l'amélioration de la séparation entre classes d'observations. Les méthodes d'analyse factorielle comme PCA, LDA et ICA qui sont connues et appliquées pour ses performances dans le domaine [19] visent à réduire les données multidimensionnelles (le nombre de variables ; notre cas d'application) en conservant au mieux l'information utile dans un sous-espace à dimension de description faible plus pertinent.

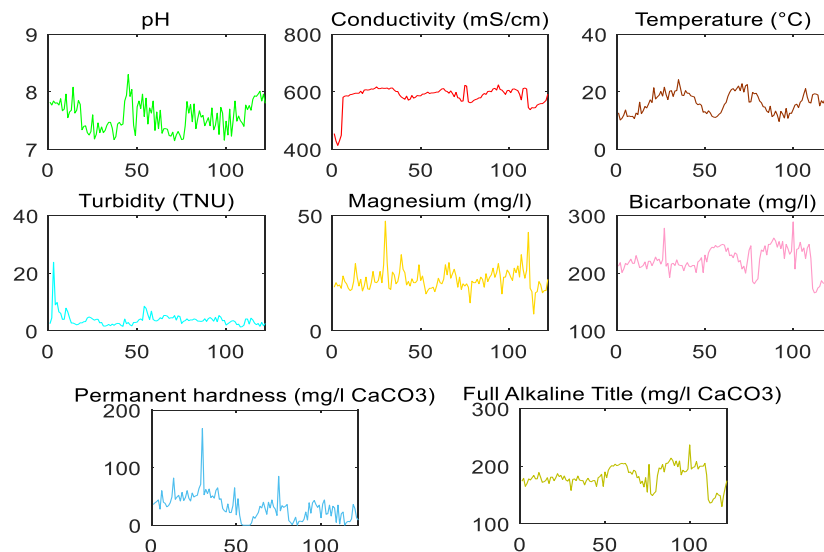
Dans ce qui suit, nous présentons l'hybridation des méthodes d'extraction et de sélection citées au-dessus avec les techniques de classification à apprentissage supervisé telles que : LSTM, SVM et ELM dans le but d'un contrôle efficace de la qualité de l'eau.

## 2.1. Sélection de variables

Dans cette section, nous allons réduire les dimensions des variables d'entrée et déterminer les variables appropriées pour construire un bon modèle de classification par extraction de caractéristiques basée sur la variance cumulative et la sélection de caractéristiques basée sur la corrélation entre les variables. À partir de l'extraction de caractéristiques à l'aide de PCA, LDA et ICA, nous pouvons savoir qu'il y a un changement dans les caractéristiques des données. La sélection des fonctionnalités sera basée sur les deux conditions suivantes :

En sélectionnant une variable parmi l'ensemble des variables utilisées dans chaque facteur qu'il indique une forte corrélation (positive ou négative). La priorité de sélection est basée sur les paramètres qui peuvent être mesurés en continu (ou à un coût non prohibitif) à l'aide des capteurs physiques, tel que pH, EC, T° et TU. Cela nous permet de créer un système de surveillance intelligent qui fonctionne en permanence et en temps réel. Contrairement aux paramètres chimiques qui sont non mesurables directement et par des moyens complexes et très coûteux dans des laboratoires, comme : Mg, B, H et FAT.

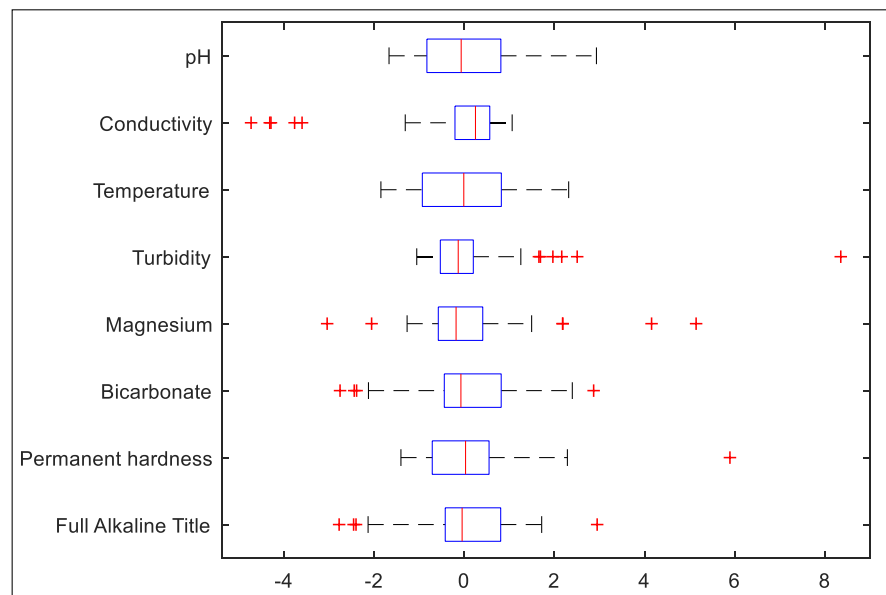
Pour mettre en œuvre cette phase, un ensemble de 122 vecteurs de 8 variables de la qualité de l'eau. La figure 4.4 représente les mesures des paramètres physico-chimiques spécifiques de la qualité des eaux brutes (Station Tilesdit).



**Figure 4.4.** Mesures des paramètres physico-chimiques spécifiques de la qualité des eaux brutes (station Tilesdit).

### 2.1.1. Sélection de variables avec PCA


La sélection de variables avec PCA consiste à standardiser les données (*z-score*). « Standardisation » signifie qu'on doit soustraire la moyenne de l'échantillon de chaque observation, puis l'on divise par l'écart type de l'échantillon. La figure 4.5 représente la variabilité du *z-score* des données. La ligne verticale (rouge) à l'intérieur de chaque case affiche la moyenne des valeurs normalisées du paramètre. Les lignes verticales (noires) qui se trouvent au-delà des cases représentent les valeurs minimales et maximales. Par exemple, dans le cas de la dureté permanente (*H*), la valeur médiane du *z-score* est de 0, tandis que les valeurs minimale et maximale du *z-score* sont de : -1,4 et 2,4 respectivement. Le symbole « + » représente les valeurs aberrantes et les moustaches s'étendent jusqu'aux points de données les plus extrêmes qui ne sont pas considérés comme des valeurs aberrantes.




**Figure 4.5.** Variabilité du *z-score* des données.

L'objectif des *z-scores* estimés est d'obtenir un ensemble de scores transformés linéairement. La méthode PCA a été utilisée après estimation des *z-scores*, pour réduire la dimensionnalité des caractéristiques qui contient 75 % de variation des valeurs propres [19]. En outre, nous pouvons comprendre qu'il y a un changement des caractéristiques des données vers des composants non corrélés. Les données d'origine et les trois premiers Composantes

Principales (CP) sont tracés sur les figures 4.6 et 4.7 respectivement. À partir de la figure 4.7, on peut observer que le cluster de données pour les trois classes est séparé.



**Figure 4.6.** Données d'origine.




**Figure 4.7.** Extraction de caractéristiques à l'aide du PCA.

L'application du PCA sur l'ensemble de données total fourni le tableau 4.2 et l'histogramme illustré dans la figure 4.8 qui montre une diminution rapide des valeurs propres.

Le tableau 4.2, montre également les corrélations entre variables pour les quatre premières composantes qui représentent 84,682% de la proportion de la variance totale.

**Tableau 4.2.** Statistiques descriptives des principaux composants créés [19].

	F1	F2	F3	F4	F5	F6	F7	F8
<b>Valeurs propres</b>								
	2.566	2.235	1.124	0.850	0.572	0.328	0.266	0.059
<b>Pourcentage de la proportion de la variance totale</b>								
	32.070	27.933	14.048	10.630	7.156	4.098	3.323	0.742
<b>Pourcentage cumulé de la proportion de la variance totale</b>								
	32.070	60.004	74.052	84.682	91.838	95.935	99.258	100
<b>Vecteurs propres des variables obtenues grâce à l'application PCA</b>								
<b>pH</b>	-0.572	-0.464	-0.253	0.516	-0.080	0.286	0.196	0.000
<b>EC</b>	0.736	0.300	-0.374	0.081	0.263	0.327	-0.211	0.003
<b>T°</b>	-0.037	0.780	-0.100	-0.446	-0.283	0.224	0.225	0.005
<b>TU</b>	-0.260	-0.473	0.729	-0.275	0.071	0.295	-0.100	0.004
<b>Mg</b>	0.381	0.479	0.430	0.478	-0.442	0.026	-0.127	-0.014
<b>B</b>	0.867	-0.411	0.107	-0.028	0.014	0.006	0.198	-0.167
<b>H</b>	-0.032	0.704	0.419	0.272	0.459	-0.021	0.205	0.019
<b>FAT</b>	0.854	-0.450	0.086	-0.002	-0.071	-0.009	0.156	0.175



**Figure 4.8.** Histogramme des valeurs propres de la composante principale.

Sélectionner 75 % de la variance totale revient à choisir les quatre premiers facteurs avec des charges positives, qui sont :

- Le premier facteur (32,070%), constitué de trois variables (EC, B et FAT)
- Le deuxième facteur (27,933%), contient deux variables seulement (T° et H)
- Le facteur trois (14,048%), est le variable TU.
- Le dernier facteur (10,630 %), représente le pH.


Dans le tableau 4.3, sont reportées les corrélations entre variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée pour les 4 premières composantes principales retenues. Nous pouvons observer que F1 (CP<sub>1</sub>) est en corrélation positive avec EC (0,736), B (0,867) et FAT (0,854). Cependant, F2 (CP<sub>2</sub>) est corrélé positivement avec T° (0,780) et H (0,704). Alors que F3 (CP<sub>3</sub>) est en corrélation positive avec TU (0,729) uniquement. F4 (CP<sub>4</sub>) est en corrélation positive avec le pH (0,516) uniquement. Enfin, on ne peut maintenir que les paramètres pH, EC, T° et TU pour construire un modèle intelligent avec des paramètres d'entrée réduits et facilement mesurables.

**Tableau 4.3.** Corrélations entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée dans les quatre premiers CP [19].

Entrées (variables)	Facteurs (CPs)			
	F1	F2	F3	F4
pH	-0.572	-0.464	-0.253	<b>0.516</b>
EC	<b>0.736</b>	0.300	-0.374	0.081
T°	-0.037	<b>0.780</b>	-0.100	-0.446
TU	-0.260	-0.473	<b>0.729</b>	-0.275
Mg	0.381	0.479	0.430	0.478
B	0.867	-0.411	0.107	-0.028
H	-0.032	0.704	0.419	0.272
FAT	0.854	-0.450	0.086	-0.002
<b>Valeurs propres</b>	2.566	2.235	1.124	0.850
<b>Proportion de la variance (%)</b>	32.070	27.933	14.048	10.630
<b>Proportion de la variance cumulée (%)</b>	32.070	60.004	74.052	84.682

### 2.1.2. Sélection de variables avec LDA

Comme nous l'avons mentionné précédemment, la technique LDA consiste à trouver une combinaison linéaire de caractéristiques qui sépare au mieux un nombre de classes à partir de données d'origine. Cette technique est utilisée comme un classificateur linéaire ou pour la réduction de dimension en entrée. L'objectif principal de LDA dans ce travail est de mettre en œuvre une réduction de dimensionnalité (extraction de caractéristiques) tout en préservant autant d'informations discriminatoires de classe que possible. Les trois premières analyses discriminantes sont tracées sur la figure 4.9, on peut observer que les clusters pour les trois classes sont bien séparés. Néanmoins, les performances de LDA sont meilleures que celles de PCA dans le clustering de chaque classe.



**Figure 4.9.** Extraction de caractéristiques à l'aide de LDA.

Le Tableau 4.4 et les données d'histogramme illustrées dans la figure 4.10 représentent les résultats de l'application de la technique LDA pour l'ensemble de données total. D'après la figure 4.10, on peut voir que seuls deux coefficients de fonction discriminante ont été extraits, puisque les variantes canoniques sont  $c-1$ , si le nombre de variables est supérieur à  $c$  et la technique LDA réduit les dimensions à  $c-1$ . La transformation de  $X$  en  $Y$  se fait en projetant les échantillons de  $X$  sur un hyperplan de dimension  $c-1$ . Où  $c$  est le nombre de classes (dans ce cas on a  $c = 3$ ).

Dans le Tableau 4.4, nous avons répertorié la corrélation entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée pour les deux premiers facteurs. A partir de ce tableau, on peut noter que les deux premiers facteurs représentent 100 % de la proportion de la variance totale :

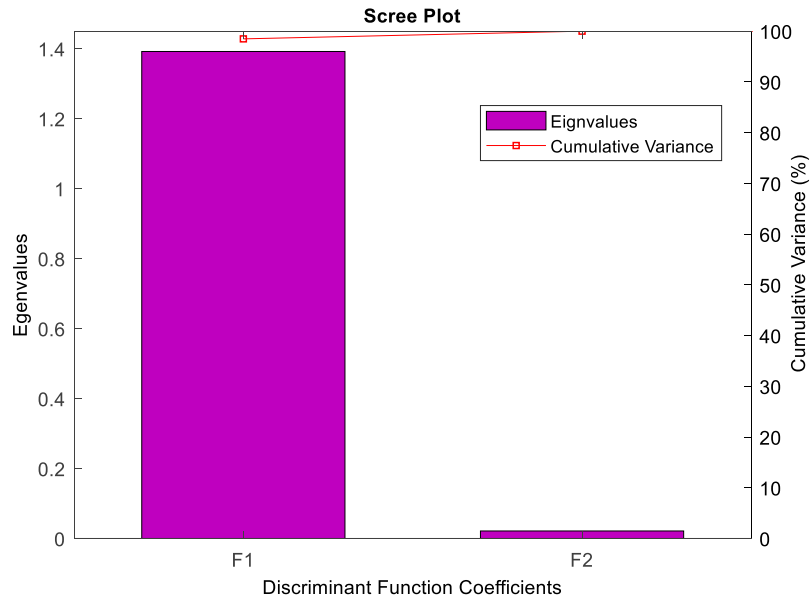
- Le premier facteur représente 98,483% de la variance totale est définie par le variable TU avec une forte charge négative ; tandis que EC et T° montrent une charge positive.
- Facteur deux avec 1,517 % est définie positivement par le pH ; tandis que : EC, Mg, B et FAT montrent une charge négative.

On observe également que F1 est corrélé positivement avec EC (0,433) et T° (0,564), et négativement avec TU (-0,942). Alors que F2 est en corrélation positive avec le pH (0,324) et négativement avec EC (-0,309), Mg (-0,663), B (-0,556) et FAT (-0,475).

En conclusion, on ne peut conserver que les paramètres TU et EC pour décider sur l'état de l'eau.

**Tableau 4.4.** Statistiques descriptives des coefficients de fonction discriminante créés [19].

	F1	F2
<b>Valeurs propres</b>		
	1.392	0.021
<b>Pourcentage de la proportion de la variance totale</b>		
	98.483	1.517
<b>Pourcentage cumulé de la proportion de la variance totale</b>		
	98.483	100
<b>Vecteurs propres des variables obtenues grâce à l'application LDA</b>		
<b>pH</b>	-0.283	0.324
<b>EC</b>	0.433	<b>-0.309</b>
<b>T°</b>	0.564	0.115
<b>TU</b>	<b>-0.942</b>	-0.049
<b>Mg</b>	0.240	-0.663
<b>B</b>	-0.112	-0.556
<b>H</b>	0.133	0.213
<b>FAT</b>	-0.120	-0.475




**Figure 4.10.** Histogramme des valeurs propres des coefficients de la fonction discriminante.


### 2.1.3. Sélection de variables avec ICA

L'objectif principal de l'utilisation d'ICA dans ce travail est d'effectuer une réduction de dimensionnalité (extraction de caractéristiques). Cela se fait en extrayant un ensemble de signaux inconnus (appelés sources CI) à partir de l'observation de quelques signaux mélanges de ces sources, en calculant une transformation linéaire qui maximise un critère mesurant l'indépendance statistique entre les sources. Les CI sont des combinaisons linéaires des variables initiales, avec une non-gaussianité maximale et donc une indépendance maximale.


Dans un premier temps, nous normalisons les données entre 0 et 1. Ensuite, nous appliquons le PCA qui est une phase préliminaire de l'algorithme ICA. La figure 4.11 montre le nuage de points pour les données étudiées dans ce travail. La figure 4.11(a) montre la dispersion des mélanges originaux qui forment une ellipse. La figure 4.11(b), représente la projection des signaux de mélange sur l'espace PCA, cela conduit à faire tourner les composants principaux à aligner avec les axes  $X_1$  et  $X_2$ , et donc l'ellipse est également tournée. Après l'étape de blanchiment, nous observons que le contour des signaux de mélange forme un cercle, c'est parce que les signaux ont une variance unitaire, comme le montre la figure 4.11(c).



(a)




(b)



**Figure 4.11.** Visualisation des signaux de mélange des données étudiées dans ce travail lors de l'étape de blanchiment. (a) nuage de points pour les signaux de mélange, (b) la projection des signaux de mélange sur l'espace PCA, c'est-à-dire la décorrélation, (c) les signaux de mélange sont mis à l'échelle après l'étape de blanchiment pour avoir une variance unitaire.

Nous pouvons maintenant appliquer l'algorithme FastICA pour extraire les CI. ICA a été utilisée pour réduire la dimensionnalité des caractéristiques qui contient 75 % de variation des valeurs propres. Les trois premiers CI sont tracés sur la figure 4.12, on peut voir que les clusters pour les trois classes sont bien séparés. Néanmoins, ICA a obtenu de meilleurs résultats que le PCA dans le clustering de chaque classe.

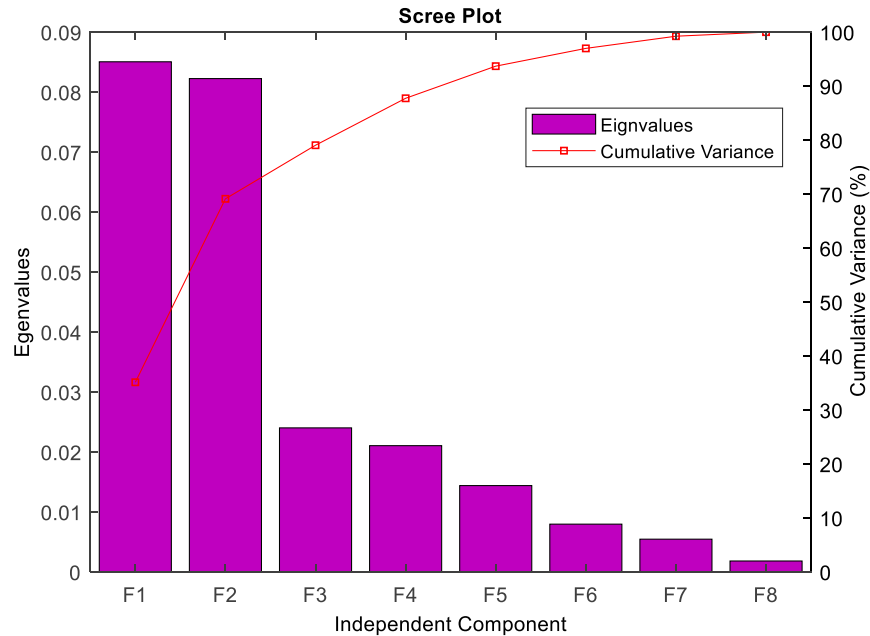
Le Tableau 4.5 et l'histogramme illustré à la figure 4.13 représentent les résultats de l'application de l'algorithme FastICA pour l'ensemble de données total. La figure 4.13 montre une diminution rapide des valeurs propres. On peut également observer que les trois premières composantes dans le tableau 4.5 représentent 79,253% de la proportion de la variance totale.



**Figure 4.12.** Extraction de caractéristiques à l'aide d'ICA.

**Tableau 4.5.** Statistiques descriptives des composants indépendants créés [19].

	<b>F1</b>	<b>F2</b>	<b>F3</b>	<b>F4</b>	<b>F5</b>	<b>F6</b>	<b>F7</b>	<b>F8</b>
<b>Valeurs propres</b>	0.085	0.082	0.024	0.021	0.014	0.008	0.005	0.002
<b>Pourcentage de la proportion de la variance totale</b>	35.270	34.025	9.959	8.714	5.809	3.320	2.075	0.830
<b>Pourcentage cumulé de la proportion de la variance totale</b>	35.270	69.295	79.253	87.967	93.776	97.095	99.170	100
<b>Vecteurs propres des variables obtenues grâce à l'application ICA</b>								
<b>pH</b>	-0.211	0.075	-0.430	0.123	-0.061	-0.323	0.467	0.201
<b>EC</b>	0.896	0.062	-0.144	-0.095	0.036	0.297	-0.359	-0.053
<b>T°</b>	0.275	-0.121	0.880	-0.073	0.248	-0.021	-0.138	-0.385
<b>TU</b>	-0.634	0.756	-0.021	-0.015	-0.143	0.031	-0.151	0.074
<b>Mg</b>	0.123	-0.078	-0.008	0.037	0.914	-0.288	-0.651	-0.889
<b>B</b>	0.109	-0.025	-0.529	-0.223	-0.226	0.501	-0.664	0.118
<b>H</b>	-0.051	-0.046	0.258	-0.177	0.580	0.314	-0.304	-0.156
<b>FAT</b>	0.105	-0.028	-0.499	0.136	-0.204	0.495	-0.678	0.047



**Figure 4.13.** Histogramme des valeurs propres des composants indépendants.

Sélectionner 75 % de la variance totale revient à choisir les trois premiers facteurs :

- Facteur un (35,270 %) : EC montre une forte charge positive, tandis que TU montre une charge négative.
- Facteur deux (34,025 %) : TU montre une forte charge positive.
- Facteur trois (9,959%) : T° montre une forte charge positive, tandis que B montre une charge négative.

Le tableau 4.6 représente la corrélation entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée pour les trois premières composantes indépendantes. Nous pouvons observer que F1 (CI<sub>1</sub>) est corrélé positivement avec EC (0,896) et négativement avec TU (-0,634). Cependant, F2 (CI<sub>2</sub>) n'est corrélé positivement qu'avec TU (0,756). Alors que F3 (CI<sub>3</sub>) est corrélé positivement avec T° (0,880) et négativement avec B (-0,529).

Enfin, on ne peut conserver que les paramètres EC, TU et T° pour construire un modèle de surveillance avec des paramètres d'entrée réduit.

**Tableau 4.6.** Corrélations entre les variables, les valeurs propres, la proportion de variance (%) et la proportion de variance cumulée dans les trois premiers CI [19].

Entrées (variables)	Facteurs (CIs)		
	F1	F2	F3
pH	-0.211	0.075	-0.430
EC	<b>0.896</b>	0.062	-0.144
T°	0.275	-0.121	<b>0.880</b>
TU	-0.634	<b>0.756</b>	-0.021
Mg	0.123	-0.078	-0.008
B	0.109	-0.025	-0.529
H	-0.051	-0.046	0.258
FAT	0.105	-0.028	-0.499
<b>Valeurs propres</b>	0.085	0.082	0.024
<b>Proportion de variance (%)</b>	35.270	34.025	9.959
<b>Proportion de la variance cumulée (%)</b>	35.270	69.295	79.253

## 2.2. Processus d'apprentissage et de classification

Dans ce travail, nous avons utilisé les trois méthodes d'apprentissage automatique expliquées ci-dessus, à savoir les LSTM RNN, les SVM et l'ELM pour la classification de différents états qualitatifs de l'eau. A signaler toutefois que la base de données réelle collectée de la station Tilesdit est identique à celle exploitée auparavant pour la sélection des caractéristiques et elle est réalisée selon les normes de potabilité recommandées. Le matériel utilisé pour effectuer nos expériences de simulation est un processeur Intel Core™ i3 de 2,40 GHz avec 4 Go de RAM.

L'architecture des LSTM RNN utilisée dans ce travail pour l'apprentissage et la classification contient une couche d'entrée de séquence suivie d'une couche LSTM. Le réseau se termine par trois couches entièrement connectées, une couche softmax et une couche de sortie de classification pour prédire les étiquettes de classe. Expérimentalement, nous avons utilisé deux couches cachées de LSTM RNN (car le temps d'apprentissage augmenterait avec un grand nombre de neurones et d'itérations, car nous n'utilisons que le CPU).

Le RBF gaussien et le polynôme sont utilisés comme fonctions noyaux dans la construction de modèles de classification SVM. Ces fonctions noyau partagent deux

paramètres de base : le premier est la borne sur les multiplicateurs de Lagrange  $C$ , et le second est le paramètre de conditionnement pour la méthode de programmation quadratique  $\gamma$ . De plus, le noyau polynomial contient également le paramètre  $d$  lié au degré du polynôme. Ces paramètres jouent un rôle crucial dans les performances des SVM. Par conséquent, il faut choisir ces paramètres judicieusement. Dans cette étude, une recherche par apprentissage de réseau adéquat et ses paramètres de noyau approprié est utilisé tel que :  $d = \{1, 2, 3\}$ ,  $C = \{2^{-3}, 2^{-2}, \dots, 2^7\}$ , et  $\gamma = \{2^{-13}, 2^{-12}, \dots, 2^{-3}\}$ . De plus, la classification multi-classe utilisant les approches *un contre un* et *un contre tous* est appliquée pour effectuer le processus de classification.

Pour ELM, de nombreux paramètres sont testés pour obtenir les modèles optimaux où la valeur de la graine est testée dans l'intervalle [5, 6, ..., 10], le nombre d'expériences dans l'intervalle [1, 2, 3, ..., 10], et le nombre de neurones dans l'intervalle [10, 11, 12, ..., 100].

Conformément aux Normes de Qualité Environnementale de l'eau, nous avons utilisé pour cette phase une base de données réelle complète constituée de 1200 échantillons. Notre problème est de savoir comment estimer les performances des modèles de classification LSTM RNN, SVM et ELM dans une étude comparative. Il est connu que lorsque nous pouvons supposer une indépendance et une distribution identique (independence and identical distribution (i.i.d.)) entre les observations, l'utilisation de la validation croisée (Cross Validation (CV)) standard  $k$ -Fold est généralement la méthode la plus appropriée [113]. En particulier dans cette étude, nous avons utilisé cette procédure de validation croisée qui peut éviter le problème de sur-apprentissage par la sélection aléatoire de sous-échantillons utilisés pour l'apprentissage des ensembles de données. Les modèles LSTM RNN sont fréquemment utilisés pour les données de séries chronologiques au sens le plus large, comme les séries chronologiques réelles, textes, etc [114-116]. Ces types de base de données sont auto-corrélés dans la plupart du temps, c'est-à-dire qu'ils dépendent de l'ordre des événements. Les données de surveillance de la qualité de l'eau sont des données de séries chronologiques et sont fortement affectées par les saisons avec une diversité saisonnière évidente. Par conséquent, la technique standard de CV  $k$ -Fold ne peut pas être appliquée directement aux données de séries chronologiques, car elle conduit à des problèmes théoriques et pratiques [113]. La raison est que dans cette technique, la dépendance entre les observations n'est pas prise en compte

puisque le CV standard *k-Fold* suppose que les valeurs de la série chronologique sont i.i.d. D'un autre côté, il existe une controverse considérable dans la littérature concernant l'utilisation du CV pour estimer la performance des modèles de prédiction de séries chronologiques. L'utilisation de méthodes CV (y compris le CV standard *k-Fold*) pour estimer la performance des modèles de prédiction de séries chronologiques est normale et que leur performance est meilleure que l'utilisation des méthodes de test hors échantillon (out-of-sample (OOS)) [117-119]. Ces techniques ne peuvent pas être appliquées pour estimer la performance des modèles de prédiction de séries chronologiques du monde réel, et ces techniques ne peuvent être utilisées qu'avec des séries chronologiques stationnaires et artificielles, alors que dans les séries chronologiques du monde réel, où les séries chronologiques est plus complexe que les séries chronologiques dans le monde artificiel, il n'est pas recommandé d'utiliser le CV, et les méthodes de test hors échantillon (OOS) et en particulier adopter une approche randomisée avec le test d'hors échantillon sont recommandées [113, 120]. Pour cela, nous avons utilisé trois méthodes de CV et deux méthodes de test OOS.

- **Les méthodes de validation croisée (CV)**

La première méthode est le CV standard *k-Fold* avec  $k = 5$  et 10. Dans le CV *k-Fold*, l'ensemble de données est d'abord divisé au hasard en sous-ensembles de taille égale. Le CV *k-Fold* prend l'échantillon de données, laisse une partie pour le test et entraîne le modèle sur le reste ( $k-1$  Folds). Ce processus est répété  $k$  fois jusqu'à ce que l'ensemble de données soit couvert.

Dans la deuxième méthode, nous avons utilisé le CV *v-Fold* (Multiple Train-Test splits) adapté aux cas de séries chronologiques [121]. La méthode consiste à répéter le processus de division de la série chronologique en ensembles de train et de test  $v$ -times (dans cette étude, nous avons utilisé CV *5-Fold*, c'est-à-dire 5 divisions). La taille du test reste fixe tandis que la taille de l'ensemble d'apprentissage augmentera pour chaque *Fold*, en tenant compte de l'ordre des données de la série chronologique.

La troisième méthode est la procédure de validation croisée bloquée (CV-BI) [120]. Cette méthode est similaire au CV standard. Mais dans cette procédure, la série chronologique est

divisée en  $k$ -blocs de taille égale sans brassage aléatoire initial, l'ordre naturel des observations étant conservé dans chaque bloc. Dans cette étude, nous avons divisé les données en 5-blocs.

- **Les méthodes de test hors échantillon (OOS)**

La première méthode est le simple Holdout (OOS.H), comme le montre la figure 3.9. Dans la méthode OOS.H, les premiers 70 % des données sont utilisés pour l'entraînement et les 30 % suivants sont utilisés pour les tests.

La deuxième méthode est *Random-Holdout* crée une partition aléatoire non stratifiée pour validation sur  $n$  observations. La méthode *Random-Holdout* sélectionne au hasard environ  $n \times p$  observations pour l'ensemble de test (évaluation). Le paramètre  $p$  doit être un scalaire, où  $0 < p < 1$ . Dans cette étude, 70 % des données sont utilisées pour l'apprentissage et 30 % des données pour les tests.

Le but recherché quant au choix d'un modèle hybride adapté, se limite à une étude en simulation effectuée sur des données réelles. Pour SVM et ELM, nous avons utilisé le CV standard *10-Fold*. Étant donné que SVM et ELM sont des techniques d'apprentissage statistique, ils supposent donc que les exemples d'entraînement sont i.i.d., dans ce cas, il serait bon d'utiliser le CV standard *k-Fold*.

Afin d'évaluer les performances de nos modèles, le critère de précision ou le taux de classification (accuracy (ACC)) comme taux de classification est effectuée et elle est définie comme suit :

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

où TP, TN, FP et FN sont respectivement vrais positifs, vrais négatifs, faux positifs et faux négatifs.

Nous cherchons dans ce qui suit d'utiliser des méthodes mixtes fait référence à la combinaison et à l'intégration de méthodes de réduction dimensionnelle PCA, LDA et ICA avec les techniques de classification LSTM RNN, SVM et ELM utilisant les différentes approche de validation croisée et ce toujours dans le but de concevoir un modèle typique de contrôle et de surveillance efficace de la qualité de l' eau propre.

Nous avons procédé à la poursuite des tests d'essais sur la base de données réelle qualitatives relatives à l'état de l'eau et quelques démonstrations a un certain nombre des scénarios. Dans ce cas-là, une base de données réelle complète constituée de 1200 vecteurs de 8 variables physico-chimiques est composée. L'étude préliminaire d'extraction des caractéristiques a permis déjà de réduire le nombre de variables à 4, 2 et 3 pour les techniques PCA, LDA et ICA respectivement.

### 2.2.1. Classification utilisant LSTM RNN

Dans cette section, nous présentons et discutons les résultats de la classification des données à l'aide des LSTM RNN avec des techniques d'extraction de caractéristiques. Aussi, nous évaluerons et comparerons les performances des méthodes utilisées pour estimer les performances des modèles de la classification. Le Tableau 4.7 montre les résultats de cette section. Dans ce tableau, nous avons répertorié la technique d'estimation des performances, la technique d'extraction de caractéristiques, la précision (ACC) pour la phase de test, le temps d'apprentissage et de test. 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 (époques) = 200, la taille du lot = 27 exemples d'apprentissage et le temps étape = 7 heures.

**Tableau 4.7.** Classification à l'aide de LSTM RNN monocouche [19].

Techniques d'estimation des performances	Technique d'extraction de caractéristiques	ACC (%)	Temps (s)	
			Apprentissage	Test
<b>OOS.H</b>	PCA	98.06	288.63	0.19
	LDA	99.17	173.45	0.11
	ICA	99.17	212.45	0.16
<b>Random-Holdout</b>	PCA	<b>99.44</b>	253.42	0.22
	LDA	<b>99.72</b>	<b>137.78</b>	<b>0.08</b>
	ICA	<b>99.72</b>	170.58	0.13
<b>Multiple Train-Test splits</b>	PCA	97.60	164.20	0.09
	LDA	97.80	114.36	0.08
	ICA	97.70	142.52	0.08
<b>CV-BI</b>	PCA	97.92	315.93	0.12
	LDA	97.92	195.39	0.08
	ICA	98.50	251.55	0.1
<b>CV 5-Fold</b>	PCA	98.50	299.16	0.09
	LDA	98.75	152.94	0.07
	ICA	98.58	209.98	0.1
<b>CV 10-Fold</b>	PCA	98.58	356.78	0.08
	LDA	98.66	175.16	0.04
	ICA	98.75	251.94	0.06

D'après le tableau 4.7 et de manière générale, les trois méthodes proposées et étudiées présentent de très bons résultats sur le plan décisionnel. Le taux de classification utilisant OOS.H est de 98,06% à 99,17%. Alors que le taux de classification utilisant Random-Holdout est de 99,44 % à 99,72 %. Le taux de classification utilisant Multiple Train-Test splits est entre 97,60 % et 97,80 %. Le taux de classification utilisant le CV-BI varie de 97,92 % à 98,50 %. Le taux de classification utilisant un CV de 5-Fold varie de 98,50 % à 98,75 tandis que le taux de classification utilisant un CV de 10-Fold varie de 98,58 % à 98,75 %. Nous pouvons observer que Random-Holdout montre la meilleure estimation suivie respectivement par OOS.H, CV k-Fold, CV-BI et Multiple Train-Test splits. Il est clair que l'utilisation des méthodes Multiple Train-Test splits, CV-BI et CV k-Fold sont les moins placés pour estimer les performances de nos modèles, car elles ignorent les composantes temporelles inhérentes. L'utilisation du OOS.H, et en particulier avec l'adoption d'une approche randomisée (méthode Random-Holdout) est l'approche la mieux placée pour estimer les performances de nos modèles à cause de leurs résultats qui sont fiables et non biaisés.

On note que le taux de classification utilisant *Random-Holdout* avec LDA et ICA est le plus élevé (99,72 %) contrairement à l'utilisation du PCA qui avait le taux de classification le plus bas (99,44 %). L'ICA est meilleure que PCA puisque l'ICA cherche à trouver les composants non seulement non corrélés mais indépendants qui sont plus importants dans la réussite du processus de classification, car la néguentropie dans l'ICA peut mieux prendre en considération les informations d'ordre supérieur des entrées d'origine que celles du PCA utilisant la matrice de covariance.

Le modèle LDA-LSTM utilisant *Random-Holdout* est plutôt bien placé du point de vue temps d'entraînement (137,78 s) et légèrement de test (0,08 s) suivi des modèles ICA-LSTM (170,58 s) et PCA-LSTM (253,42 s) respectivement, ce qui lui confère l'avantage d'une possibilité d'intégration au sein d'un système de contrôle en temps réel. Ce modèle est moins complexe en matière de calcul et les dimensions d'entrée et en conséquence en capacité de mémoire comparativement aux autres modèles.

En général, tous les modèles ont un temps d'entraînement relativement long, qui exige en conséquence un traitement hors ligne devant être réalisé par le système de contrôle et de surveillance. Dans le cas d'une utilisation en temps réel, seul le temps de test est pris en

considération. Dans notre étude, le temps d'exécution de la phase de test est très faible qui lui confère l'avantage de décider sur la qualité de l'eau de façon dynamique par le système présenté de la figure 4.1. Le temps de classification étant de 0,08 s, 0,13 s et 0,22 s pour LDA-LSTM, ICA-LSTM et PCA-LSTM respectivement.

Les résultats d'apprentissage présentés dans le tableau 4.8 de modèle LSTM RNN à deux couches avec la méthode *Random-Holdout* sont obtenus en utilisant les paramètres tels que : *Hiddnum* = 100 pour chaque couche, les *époques* = 200, la taille du lot = 27 exemples d'apprentissage et le pas de temps = 7 heures.

**Tableau 4.8.** Classification utilisant des RNR LSTM à deux couches avec la méthode *Random-Holdout*.

Technique d'extraction de caractéristiques	ACC (%)	Temps (s)	
		Apprentissage	Test
PCA	97.22	354.92	0.34
LDA	98.61	251.58	0.22
ICA	97.50	307	0.23

L'utilisation de deux couches de LSTM RNN avec la méthode *Random-Holdout* n'a pas amélioré les performances de classification, comme le montre le tableau ci-dessus. Sur la base de l'étude de Yang Liu [102], cela peut être expliqué que les LSTM RNN à couche unique peuvent fournir une précision améliorée pour la prédiction d'intervalles de temps importants.

### 2.2.2. Classification utilisant SVM multi-classes

Les résultats de la classification de données à l'aide de techniques d'extraction de caractéristiques et multi-classes SVM ainsi que la complexité temporelle des modèles sont présentés. De plus, nous introduisons l'effet de la sélection de la fonction noyau, à savoir le noyau RBF gaussien et le noyau polynomial et ces paramètres. Le bon choix de la fonction noyau et ses paramètres appropriés joue un rôle majeur dans l'amélioration des performances des SVM. Le but de l'utilisation de la fonction noyau est de transformer les données de l'espace d'entrée en un espace de caractéristiques de dimension supérieure. Une sélection incorrecte des paramètres  $d$ ,  $C$  et  $\gamma$  peut entraîner des problèmes de sur-ajustement ou de sous-ajustement. Pour l'utilisation du noyau RBF gaussien, nous avons recherché la plage de paramètres  $\gamma = \{2^{-13}, 2^{-12}, \dots, 2^{-3}\}$  et  $C = \{2^{-3}, 2^{-2}, \dots, 2^7\}$ . Pour le noyau polynomial, nous avons évalué des paires de  $(d, C, \gamma)$  de l'intervalle  $C = \{2^{-3}, 2^{-2}, \dots, 2^7\}$ ,  $d = \{1, 2, 3\}$ ,

et  $\gamma = \{2^{-13}, 2^{-12}, \dots, 2^{-3}\}$ . Afin d'estimer les performances de nos modèles, nous avons utilisé le CV 10-Fold (puisque SVM est une technique d'apprentissage statistique, il suppose que les exemples d'entraînement sont i.i.d., dans ce cas, il serait bon d'utiliser le standard CV *k-Fold*). Les résultats de cette étude peuvent être présentés dans le Tableau 4.9. Les paramètres tels que : la technique d'extraction de caractéristiques, la fonction noyau, la stratégie de classification multi-classe et ses paramètres appropriés, le taux de classification (ACC) de la phase de test le temps d'apprentissage et de test sont tous affichés.

**Tableau 4.9.** Classification utilisant SVM multi-classe [19].

Technique d'extraction de caractéristiques	Noyau	Stratégie multi-classes	ACC (%)	Temps (s)	
				Apprentissage	Test
PCA	Polynôme ( $d, C, \gamma$ )	Un vs. Un ( $1, 2^5, 2^{-7}$ )	<b>99.25</b>	0.6	0
		Un vs. Tous ( $1, 2^7, 2^{-9}$ )	98.00	2.58	0.03
	RBF gaussien ( $C, \gamma$ )	Un vs. Un ( $2^2, 2^{-11}$ )	95.17	9.86	0
		Un vs. Tous ( $2^7, 2^{-6}$ )	95.17	27.66	0.18
LDA	Polynôme ( $d, C, \gamma$ )	Un vs. Un ( $1, 2^6, 2^{-9}$ )	<b>99.43</b>	0.56	0
		Un vs. Tous ( $1, 2^7, 2^{-13}$ )	97.92	1.98	0.01
	RBF gaussien ( $C, \gamma$ )	Un vs. Un ( $2^7, 2^{-11}$ )	97.92	2.69	0.01
		Un vs. Tous ( $2^5, 2^{-9}$ )	97.84	6.87	0.1
ICA	Polynôme ( $d, C, \gamma$ )	Un vs. Un ( $1, 2^6, 2^{-10}$ )	<b>99.42</b>	0.55	0.01
		Un vs. Tous ( $1, 2^7, 2^{-11}$ )	98.00	2.11	0.01
	RBF gaussien ( $C, \gamma$ )	Un vs. Un ( $2^6, 2^{-13}$ )	95.17	8.47	0
		Un vs. Tous ( $2^7, 2^{-8}$ )	95.42	22.4	0.17

D'après le tableau 4.9, le taux de classification de modèle PCA-SVM varie de 95,17 % à 99,25 %. Alors que le taux de classification avec le modèle LDA-SVM varie de 97,84 % à 99,43 %. Tandis que le taux de classification avec ICA-SVM varie de 95,17 % à 99,42 %. Les performances du noyau polynomial sont meilleures que celles du noyau RBF gaussien utilisant les deux stratégies un contre un et un contre tous pour tous les technique d'extraction de caractéristiques.

Le taux de classification du modèle LDA-SVM avec la stratégie *un contre un* utilisant le noyau polynomial avec ( $1, 2^6, 2^{-9}$ ) est le plus élevé de 99,43%, et pour un noyau RBF gaussien avec ( $2^7, 2^{-11}$ ) est de 97,92%. Le taux de classification du modèle ICA-SVM

utilisant le noyau polynomial avec  $(1, 2^6, 2^{-10})$  est le plus élevé de 99,42%, et pour un noyau RBF gaussien avec  $(2^6, 2^{-13})$  est de 95,17%. Le taux de classification du modèle PCA-SVM utilisant le noyau polynomial avec  $(1, 2^5, 2^{-7})$  est le plus élevé de 99,25%, et pour un noyau RBF gaussien avec  $(2^2, 2^{-11})$  est de 95,1%.

Le taux de classification de deux modèles ICA-SVM et PCA-SVM avec la stratégie *un contre tous* utilisant le noyau polynomial avec  $(1, 2^7, 2^{-11})$  et  $(1, 2^7, 2^{-9})$  respectivement est le plus élevé de 98%. Le taux de classification du modèle LDA-SVM utilisant le noyau polynomial avec  $(1, 2^7, 2^{-13})$  est de 97,92 % et pour un noyau RBF gaussien avec  $(2^5, 2^{-9})$  est de 97,84 %. Le taux de classification du modèle ICA-SVM utilisant le noyau RBF gaussien avec  $(2^7, 2^{-8})$  est de 95,42 %, et pour le modèle PCA-SVM utilisant un noyau RBF gaussien avec  $(2^7, 2^{-6})$  est de 95,17%.

Enfin, l'approche de classification multi-classe de combinaison avec des SVM et l'extraction des caractéristiques, donne de meilleures performances sur le plan technique (très peu de temps d'apprentissage ; une faible complexité de calcul), avec une grande précision du calcul (taux de classification) et un très faible temps d'exécution (temps de test).

### 2.2.3. Classification utilisant ELM

Dans cette section, nous présentons l'application de la technique ELM à l'aide de techniques d'extraction de caractéristiques ainsi que la complexité temporelle des modèles. Les résultats de cette étude peuvent être présentés dans le Tableau 4.10. Les paramètres tels que : la technique d'extraction de caractéristiques, la graine, le nombre d'expérimentes, le nombre de neurones, le taux de classification (ACC) de la phase de test le temps d'apprentissage et de test sont tous présentés.

**Tableau 4.10.** Classification utilisant ELM.

Technique d'extraction de caractéristiques	La graine	Nombre d'expérimentes	Nombre de neurones	ACC (%)	Temps (s)	
					Apprentissage	Test
PCA	6	5	77	95.83	0.0625	0.003125
LDA	7	5	55	98.06	0.0313	0.003125
ICA	9	2	90	98.06	0.0313	0.003125

Comme le montre le tableau 4.10, le taux de classification avec LDA-ELM et ICA-ELM est de 98,06 %. Le PCA-ELM avait un taux de classification moins faible (95,83 %).

On peut également noter que tous les modèles ELM testés ont obtenus un très peu de temps pour effectuer les deux phases (Apprentissage et test) qui mener donc une faible complexité de calcul.

### 2.3. Analyse et évaluation

Les principaux résultats correspondant aux différents modèles hybrides évalués pour la classification de la qualité de l'eau, sont récapitulés dans le tableau 4.11.

**Tableau. 4.11.** Caractéristiques principales des modèles (LDA-LSTM, LDA-SVM et LDA-ELM).

Modèles	ACC (%)	Temps (s)	
		Apprentissage	Test
<b>LDA-LSTM</b> <i>Monocouche</i> <i>Random-Holdout</i>	99.72	137.78	0.08
<b>LDA-SVM</b> Polynomial Un vs. Un ( $1, 2^6, 2^{-9}$ )	99.43	0.56	0
<b>LDA-ELM</b> (7, 5, 55)	98.06	0.0313	0.003125

Il apparait clairement que les trois modèles d'extraction et de classification multi-classe proposées et étudiés présentent de très bons résultats sur le plan décisionnel. L'effet de réduction dimensionnelle apporte sans doute des améliorations sur les performances de classification. La technique d'extraction de caractéristiques LDA est le mieux placée par rapport aux autres techniques ICA et PCA. Par conséquent, le temps d'apprentissage de ce modèle est bien clair. Ce modèle qualifié de performances intéressantes, peut donc être utilisé dans un système de contrôle en temps réel. La réduction dimensionnelle a engendré un double effet positif sur les plans, aussi bien technique (complexité du calcul plus faible), qu'économique (peu de capteurs en entrée avec un faible coût). Le modèle ELM est plutôt mieux placé comparativement avec la technique SVM en matière du temps d'apprentissage et de test, ce qui lui confère l'avantage d'une possibilité d'intégration au sein d'un système de contrôle en temps réel. Le temps de test est pratiquement très faible pour les trois méthodes. Cependant, le modèle LSTM RNN a un temps d'entraînement relativement long, qui exige en conséquence un traitement hors ligne devant être réalisé par le système de contrôle et de surveillance. Ce modèle souffre particulièrement avec le modèle ELM d'un handicap majeur lié à son diversité des architectures qui ne sont pas toujours standard. Par contre, le concept d'apprentissage du modèle SVM est basé sur des exemples (architecture standard du réseau)

[14]. L'amélioration sensible et les performances remarquées pour le modèle LSTM RNN en matière de précision laissent la possibilité d'envisager son intégration dans un système de contrôle et de surveillance. La collecte en permanence de l'information et des données supervisées par un expert contribue sans doute à enrichir une base de données qu'on veut qu'elle soit la plus complète possible pour le modèle de décision implanté dans notre système de surveillance. Bien que les LSTM RNN sont très pratiques avec des grandes bases de données (*Big data*). Le système de surveillance doit donc pouvoir garantir dans le même temps un contrôle direct de l'eau et un entraînement en arrière-plan (en temps différé).

### **Conclusion**

Ce dernier chapitre a été consacré à une étude comparative de simulation pour évaluer les performances de notre approche basée sur l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) avec les techniques d'apprentissage automatique LSTM RNN, SVM et ELM appliquée dans le domaine de la surveillance de la qualité de l'eau. Cette étude a permis d'analyser plusieurs scénarios afin de sélectionner l'approche de décision la plus appropriée. L'objectif était de développer un système multi-capteurs permettant une surveillance automatique et intelligente de la qualité de l'eau en temps réel. Les modèles étudiés ont été évalués sur la base de paramètres liés au temps d'apprentissage et au taux de classification. L'analyse et l'évaluation des résultats obtenus, a permis d'opter un multi-choix adaptés au problème posé. Les trois techniques ont fournis de très bons résultats de classification. Les résultats obtenus dans cette étude ont montré que l'approche proposée a une grande efficacité dans la surveillance de la qualité de l'eau et notamment l'intégration de la technique LDA-LSTM dans un système de surveillance permis de faire un contrôle direct de l'eau et un entraînement en arrière-plan (en temps différé). Notre approche proposée peut constituer une alternative prometteuse pour une surveillance intelligente et automatisée de la qualité de l'eau à l'avenir.

## CONCLUSION GENERALE

L'étude présentée dans cette thèse a été une contribution au développement d'un système multi-capteurs intelligent pour la surveillance de la qualité de l'eau basé sur l'intégration et l'hybridation de techniques d'extraction de caractéristiques (PCA, LDA et ICA) avec des techniques d'apprentissage automatique (LSTM RNN, SVM et ELM). Le système doit être réalisé dans le but d'assurer un contrôle et surveillance efficace et en temps réel des installations de production et de qualité d'eau potable à partir des capteurs physico-chimiques, tels que le pH, la température, la turbidité et la conductivité, etc. Dans ce domaine, la surveillance automatique et intelligente est devenue un moyen très attractif pour traiter le problème des coûts d'exploitation élevés et du temps long requis pour le processus de surveillance. Notre contribution dans ce modeste travail peut alors être considérée comme une solution à progrès technologiques qui ont été réalisés ces dernières décennies pour résoudre des problèmes d'importance stratégique d'intérêt locale et national, en utilisant des outils modernes basés sur des technologies avancées, dans l'intérêt d'un contrôle plus efficace et une surveillance intelligente et automatisée de la qualité de l'eau propre.

Le travail présenté dans cette thèse a été organisé en quatre chapitres principaux. Le premier chapitre a été consacré aux généralités liées à l'eau propre et ses différentes caractéristiques ainsi que la chaîne habituelle de production, de traitement et d'exploitation d'eau propre la plus connue et courante et les différentes méthodes de surveillance industrielle. Dans le deuxième chapitre, le problème d'avoir un grand nombre de dimensions et son impact sur l'apprentissage automatique a été abordé. Les différentes méthodes pour réduire les dimensions ont été présentées. Dans ce contexte, les méthodes les plus fréquemment utilisées pour l'extraction et la sélection de caractéristiques (PCA, LDA et ICA) ont été présentées. Dans le troisième chapitre, les méthodes d'apprentissage automatique utilisées pour développer le modèle de surveillance de la qualité de l'eau ont été présentées. Dans ce chapitre, trois méthodes (LSTM RNN, SVM et ELM) fondés sur l'apprentissage supervisé ont

été exposés. Le concept de chaque technique, sa structure, et ses caractéristiques générales ont été présentées. L'architecture générale des méthodes SVM et ELM a été également décrite. Le quatrième chapitre a été consacré à la simulation dans le but d'appliquer les techniques d'extraction et de sélection et de classification proposées comme solution pour concevoir un système automatisé et intelligent de surveillance de la qualité de l'eau en temps réel. La technique appropriée pour la conception de ce système a été choisie sur la base d'une étude d'évaluation des performances de chacune des méthodes présentées en matière de taux de précision de la classification, temps d'apprentissage et de test et la complexité de calcul. Dans notre problématique de classification multi-classe, les techniques ont fournies d'excellents résultats de simulation. La base de données collectée de la station d'étude (Tiledit) a été bien appliquée et a montré l'efficacité de notre approche de surveillance.

D'après les résultats obtenus dans ce travail, il a été constaté que tous les modèles présentent d'excellents résultats en termes de taux de précision de classification. La réduction dimensionnelle a engendré un double effet positif sur les plans, aussi bien technique (complexité du calcul plus faible), qu'économique (peu de capteurs en entrée avec un faible coût). Le modèle ELM est plutôt le mieux placé en matière du temps d'apprentissage et de test, ce qui lui confère l'avantage d'une possibilité d'intégration au sein d'un système de contrôle en temps réel. Le temps de test est pratiquement très faible pour les trois méthodes. Cependant, le modèle LSTM RNN a un temps d'entraînement relativement long, qui exige en conséquence un traitement hors ligne devant être réalisé par le système de contrôle et de surveillance. Ce modèle souffre particulièrement avec le modèle ELM d'un handicap majeur lié à son diversité des architectures qui ne sont pas toujours standard. Par contre, le concept d'apprentissage du modèle SVM est basé sur des exemples (architecture standard du réseau). L'amélioration sensible et les performances remarquées pour le modèle LSTM RNN en matière de précision laissent la possibilité d'envisager son intégration dans un système de contrôle et de surveillance. La collecte en permanence de l'information et des données supervisées par un expert contribue sans doute à enrichir une base de données qu'on veut qu'elle soit la plus complète possible pour le modèle de décision implanté dans notre système de surveillance. Bien que les LSTM RNN sont très pratiques avec des grandes bases de données (*Big data*). Le système de surveillance doit donc pouvoir garantir dans le même temps un contrôle direct de l'eau et un entraînement en arrière-plan (en temps différé).

L'intérêt théorique et pratique de la technique LSTM RNN étant montré, les performances et les avantages sont nombreux, que ce soit sur le plan de son adaptation pour résoudre des problèmes de classification multi-classes ou d'extraction des caractéristiques. L'usage d'un prétraitement des données intrinsèque de ce modèle avec les grandes bases de données dans un but de réduction de dimensionnalité, a confirmé davantage encore cet intérêt.

Les performances obtenues peuvent être améliorées en utilisant des bases de données plus importantes et significatives. Dans ce cas, les capteurs logiciels peuvent jouer un rôle efficace en présence de paramètres chimiques qui ne peuvent pas être mesurés en continu. L'utilisation de techniques d'extraction de caractéristiques non linéaires telles que l'analyse en composantes principales à noyau (ou kernel principal component analysis (KPCA)), l'analyse discriminante à noyau (ou kernel discriminant analysis (KDA)) et l'analyse en composantes indépendantes à noyau (ou kernel independent component analysis (KICA)) peut aboutir à sélectionner des variables plus efficaces et ainsi améliorer les performances de classification et la prise de décision. L'utilisation d'outils de classification plus puissants tels que les unités récurrentes fermées (ou Gated Recurrent Units (GRU)) et le LSTM convolutif (ou convolutional LSTM (ConvLSTM)) peut également améliorer considérablement les performances. Le temps correspondant à la phase d'apprentissage reste relativement long pour les modèles PCA-LSTM, LDA-LSTM et ICA-LSTM, ce qui permet d'envisager l'utilisation d'algorithmes d'optimisation d'hyperparamètres comme l'optimisation bayésienne. D'autre part, le contrôle de la potabilité peut être traité de manière dynamique par le système de surveillance multi-capteurs proposé, car le temps de test est encore faible. Enfin, cette application peut être une alternative prometteuse pour une surveillance automatique et intelligente de la qualité de l'eau potable à l'avenir.

# REFERENCES

- [1] “UNESCO International Water Conference: Leveraging inter sectorality for sustainable water security and peace”. <https://en.unesco.org/events/unesco-international-water-conference-leveraging-intersectorality-sustainable-water-security>, 2019 (accessed 27 December 2019).
- [2] M. Tripathi, S. K. Singal, “Use of Principal Component Analysis for parameter selection for development of a novel Water Quality Index : A case study of river Ganga India”, *Ecol. Indic.* 96 (2019) 430–436. <https://doi.org/10.1016/j.ecolind.2018.09.025>.
- [3] T. Ma, N. Zhao, Y. Ni, J. Yi, J. P. Wilson, L. He, Y. Du, T. Pei, C. Zhou, C. Song, W. Cheng, 2020. “China's improving inland surface water quality since 2003”. *Sci. Adv.* 6, eaau3798. DOI: 10.1126/sciadv.aau3798.
- [4] S. Díaz et al., 2019. “Pervasive human-driven decline of life on Earth points to the need for transformative change”. *Science.* 366, eaax3100. DOI: 10.1126/science.aax3100.
- [5] V. Randriamiarisoa, “L’eau, Un problème mondial”, Biodiversity reporting award, (2003). <http://www.biodiversityreporting.org>.
- [6] “Les propriétés de développement social, L’eau potable”, Document : ACIDI « Agence canadienne de développement international » (2004).
- [7] P. Schwaller, “L’or bleu, un patrimoine à protéger” Salon AQUA, Eau & Vie, Bulle, Suisse (2002). <http://www.lyoba.ch/>.
- [8] P. Pal, “Industrial Water Treatment Process Technology”, 1st Edition, Elsevier, 2017.
- [9] World Health Organization, UNICEF, “Progress on sanitation and drinking water : 2015 update and MDG assessment”, (2015).
- [10] H. Lockwood, S. Smits, “Supporting rural water supply. Moving towards a service delivery approach”, (2011).
- [11] M. A. Shannon et al. “Science and technology for water purification in the coming decades”, *Nature* 452 (2008) 301-310.

- [12] M. Djerioui, M. Bouamar, M. Ladjal, A. Zerguine, “Chlorine Soft Sensor Based on Extreme Learning Machine for Water Quality Monitoring”, *Arab. J. Sci. Eng.* 44 (2019) 2033–2044. <https://doi.org/10.1007/s13369-018-3253-8>.
- [13] 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).
- [14] M. Ladjal, "Contribution au développement de systèmes de surveillance innovants dédiés au contrôle de la qualité des eaux potables", Thèse de doctorat, Université de M'sila, Algérie (2013).
- [15] L. Xie, M. Yin, X. Yin, Y. Liu, G. Yin, “Low-Rank Sparse Preserving Projections for Dimensionality Reduction”, *IEEE Trans. on Image Process.* 27(11) (2018) 5261–5274. DOI: 10.1109/TIP.2018.2855426.
- [16] A. Subasi, “Feature Extraction and Dimension Reduction”. In: *Practical Guide for Biomedical Signals Analysis Using Machine Learning Techniques*, Elsevier, 2019, pp. 193–275. <https://doi.org/10.1016/B978-0-12-817444-9.00004-0>.
- [17] A. Subasi, M. I. Gursoy, “EEG signal classification using PCA, ICA, LDA and support vector machines”, *Expert Syst. Appl.* 37 (2010) 8659–8666. doi:10.1016/j.eswa.2010.06.065.
- [18] N. Palluat, D. Racoceanu, N. Zerhouni, “A neuro-fuzzy monitoring system: Application to flexible production system”, *Computers in Industries*, 57(4) (2006) 528-538. <https://doi.org/10.1016/j.compind.2006.02.013>.
- [19] S. Dilmi, M. Ladjal, “A novel approach for water quality classification based on the integration of deep learning and feature extraction techniques”. *Chemometrics and Intelligent Laboratory Systems* 214 (2021) 104329. <https://doi.org/10.1016/j.chemolab.2021.104329>.
- [20] Tiyasha, T. M. Tung, Z. M. Yaseen, “A survey on river water quality modelling using artificial intelligence models: 2000-2020”, *J. Hydrol.* (2020). <https://doi.org/10.1016/j.jhydrol.2020.124670>.

- [21] T. Rajaei, S. Khani, M. Ravansalar, “Artificial intelligence-based single and hybrid models for prediction of water quality in rivers: A review”, *Chemometrics and Intelligent Laboratory Systems*, (2020). <https://doi.org/10.1016/j.chemolab.2020.103978>.
- [22] D. Dezfooli, S.-M. Hosseini-Moghari, K. Ebrahimi, S. Araghinejad, “Classification of water quality status based on minimum quality parameters: application of machine learning techniques”, *Model. Earth Syst. Environ.* 4 (2018) 311–324. <https://doi.org/10.1007/s40808-017-0406-9>.
- [23] T. H. H. Aldhyani, M. Al-Yaari, H. Alkahtani, M. Maashi, “Water Quality Prediction Using Artificial Intelligence Algorithms”, *Appl. Bionics and Biomech.* (2020) 1–12. <https://doi.org/10.1155/2020/6659314>.
- [24] C. Gakii, J. Jepkoech, “A classification model for water quality analysis using decision tree”, *Eur. J. Comput. Sci. Inf. Technol.* 7(3) (2019) 1–8.
- [25] R. R. 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).
- [26] M. Kahoul, M. Touhami, “Evaluation de la qualité physico-chimique des eaux de consommation de la ville d’Annaba (Algérie)”, *Larhyss/Journal*, 19 (2014) 129-138.
- [27] W. Yan, et al., “Comprehensive assessment and visualized monitoring of urban drinking water quality”, *Chemometrics and Intelligent Laboratory Systems*, 155 (2016) 26-35.
- [28] M. Djerioui, “Contribution au Développement de Systèmes Multicapteurs Intelligents Dédiés à la Surveillance et au Contrôle de la Qualité des Eaux Propres”, Thèse de doctorat, Université de M’sila, Algérie (2019).
- [29] “Chapter 2 water quality characteristics”. [https://echo2.epfl.ch/VICAIRE/mod\\_2/chapt\\_2/main.htm#:~:text=The%20temperature%20of%20water%20affects,of%20dissolved%20gases%20and%20etc.](https://echo2.epfl.ch/VICAIRE/mod_2/chapt_2/main.htm#:~:text=The%20temperature%20of%20water%20affects,of%20dissolved%20gases%20and%20etc.)

- [30] “Characteristics of Water – Physical, Chemical and Biological”. <https://theconstructor.org/environmental-engg/characteristics-of-water-physical-chemical-biological/4735/>.
- [31] Disha Experts, “Civil Engineering Coal India Management Trainee Tier I & II Exam 2020 Guide”, Disha Publications, 3 ed. (2020).
- [32] K. M. Vigil, “Clean Water: An Introduction to Water Quality and Water Pollution Control”. Oregon State University Press, 2nd ed. (2003).
- [33] A. Pooja, “Physical, Chemical and Biological Characteristics of Water”, e Content Module (2017). [https://www.researchgate.net/publication/322419790\\_Physical\\_Chemical\\_and\\_Biological\\_Characteristics\\_of\\_Water\\_e\\_Content\\_Module](https://www.researchgate.net/publication/322419790_Physical_Chemical_and_Biological_Characteristics_of_Water_e_Content_Module).
- [34] D. Chapman, V. Kimstach, “Selection of Water Quality Variable. W of Biota, Sediments and Water Quality Assessments: A Guide to of the Use of Biota”. In: Sediments and Water in Environment Monitoring, Chapman Edition, E& FN Spon, London, 1996, pp. 59-126.
- [35] S. Panguluri, S. Haji, J. Adams, A. Patel, “Drinking Water Purity – A Market Outlook”. In: S. Ahuja (ed.) Comprehensive Water Quality and Purification, Elsevier, 2014, pp. 1-18. <https://doi.org/10.1016/B978-0-12-382182-9.00094-3>.
- [36] D. Yan, Z. Sun, J. Wang, L. Wang, R. Pan, Q. Wu, X. Liu, 2019. “Enhanced Coagulation with Mn(III) Pre-Oxidation for Treatment of Micro-Polluted Raw Water”. *Water*, 11, 2302. doi:10.3390/w11112302.
- [37] “Processes and technologies, drinking water treatment, surface water treatment systems, pre-oxydation”. <https://www.suezwaterhandbook.com/processes-and-technologies/drinking-water-treatment/surface-water-treatment-systems/pre-oxydation>.
- [38] “Handbook of Industrial Water Treatment, External Treatment, Chapter 05 – Clarification”. <https://www.suezwatertechnologies.com/handbook/chapter-05-clarification>.
- [39] A. B. Pandit, J. K. Kumar, “Drinking Water Disinfection techniques”. Taylor & Francis Group, CRC Press (2013).

- [40] S. Dash, V. Venkatasubramanian, “Challenges in the industrial applications of fault diagnostic systems”. In: proceedings of the Conference on Process Systems Engineering Computing & Chemical Engineering, Keystone, Colorado, USA, pp. 785-791, (2000).
- [41] M. Combacau, “Commande et surveillance des systèmes à évènements discrets complexes: Application aux ateliers flexibles”, Thèse de doctorat, Université Paul Sabatier, Toulouse, France, (1991).
- [42] D. 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, (2006).
- [43] A. 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).
- [44] C.V. I. 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).
- [45] H. R. Hernandez 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).
- [46] J. Montmain, “Interprétation qualitative de simulation pour le diagnostic en ligne de procédé continu”, Thèse de doctorat, Institut National Polytechnique de Grenoble, France (1992).
- [47] H. Derbel, “Diagnostic á base de modèles des systèmes temporisés et d’une sous-classe de systèmes dynamiques hybrides”, Thèse de doctorat, Université Joseph-Fourier - Grenoble I, France (2009).
- [48] M. 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, Université de Franche- Comté, France, (2003).
- [49] M. Basseville, “Detecting changes in signals and systems - A survey”, *Automatica*, 24 (1988) 309-326.

- [50] K. Hameed, et al., “A comprehensive review of fruit and vegetable classification techniques”, *Image and Vision Computing*, 80 (2018) 24-44.
- [51] A. Belaout, et al., “Multiclass adaptive neuro-fuzzy classifier and feature selection techniques for photovoltaic array fault detection and classification”, *Renewable Energy*, 127 (2018) 548-558.
- [52] J. Mushava, M. Murray, “An experimental comparison of classification techniques in debt recoveries scoring: Evidence from South Africa's unsecured lending market”, *Expert Systems with Applications*, 111 (2018) 35-50.
- [53] F. Qiao, B. Li, Y. Zhang, H. Guo, W. Li, S. Zhou, “A Fast and Accurate Recognition of ECG Signals Based on ELM-LRF and BLSTM Algorithm”, *IEEE Access* 8 (2020) 71189-71198. DOI: 10.1109/ACCESS.2020.2987930.
- [54] W. Deng, S. Zhang, H. Zhao, X. Yang, “A Novel Fault Diagnosis Method Based on Integrating Empirical Wavelet Transform and Fuzzy Entropy for Motor Bearing”. *IEEE Access* 6 (2018) 35042 – 35056.
- [55] R. O. Alabi et al. “Comparison of supervised machine learning classification techniques in prediction of locoregional recurrences in early oral tongue cancer”. *International Journal of Medical Informatics* 136 (2020) 104068. <https://doi.org/10.1016/j.ijmedinf.2019.104068>.
- [56] J. Vasavi, M. S. Abirami, “A Qualitative Performance Comparison Of Supervised Machine Learning Algorithms For Iris Recognition”. *European Journal of Molecular & Clinical Medicine* 7(6) (2020) 1937-1946.
- [57] J. E. Garcia-Bracamonte et al., “An Approach on MCSA-Based Fault Detection Using Independent Component Analysis and Neural Networks”. *IEEE Transactions on Instrumentation and Measurement*, 68(5) (2019) 1353-1361. <https://doi.org/10.1109/tim.2019.2900143>
- [58] S. H. Haji, A. M. Abdulazeez, D. Q. Zeebaree, F. Y. H. Ahmed, D. A. Zebari, “The Impact of Different Data Mining Classification Techniques in Different Datasets”. In: 2021 IEEE Symposium on Industrial Electronics & Applications (ISIEA) (2021).

- [59] A. Widodo, B.-S. Yang, T. Han, “Combination of independent component analysis and support vector machines for intelligent faults diagnosis of induction motors”. *Expert Systems with Applications* 32 (2007) 299–312.
- [60] K. El Bouchefry, R. S. de Souza, “Learning in Big Data: Introduction to Machine Learning”. In: P. Škoda, F. Adam (Eds.) *Knowledge Discovery in Big Data from Astronomy and Earth Observation*, Elsevier, 2020, pp. 225-249. <https://doi.org/10.1016/B978-0-12-819154-5.00023-0>.
- [61] W. L. Martinez, A. R. Martinez, J. L. Solka, “Exploratory Data Analysis with MATLAB®”, third ed., CRC Press, 2017.
- [62] J. de Leeuw, “Principal component analysis of binary data by iterated singular value decomposition”, *Comput. Stat. & Data Anal.* 50(1) (2006) 21–39.
- [63] A. Meyer-Baese, V. Schmid, “Feature Selection and Extraction”. In: A. Meyer-Baese, V. Schmid (Eds.) *Pattern Recognition and Signal Analysis in Medical Imaging (Second Edition)*, Academic Press, 2014, pp. 21-69. <https://doi.org/10.1016/B978-0-12-409545-8.00002-9>.
- [64] A. Tharwat, “Principal Component Analysis - A Tutorial”, *International Journal of Applied Pattern Recognition*, 3(3) (2016) 197 - 240.
- [65] C. M. Bishop, “Pattern recognition and machine learning”, Springer-Verlag New York, 2006.
- [66] N. Kambhatla, T. K. Leen, “Dimension reduction by local principal component analysis”, *Neural Computation*, 9(7) (1997) 1493–1516.
- [67] J. Shlens, “A tutorial on principal component analysis”, *Systems Neurobiology Laboratory, Salk Institute for Biological Studies* (2014).
- [68] F. Pan, G. Song, X. Gan and Q. Gu, “Consistent feature selection and its application to face recognition”, *Journal of Intelligent Information Systems* 43(2) (2014) 307–321. doi:10.1007/s10844-014-0324-5.
- [69] S. Balakrishnama, A. Ganapathiraju, “Linear discriminant analysis-a brief tutorial”, *Institute for Signal and Information Processing*, (1998) 1–8.

- [70] A. Tharwat, T. Gaber, A. Ibrahim, A. E. Hassanien, “Linear discriminant analysis: A detailed tutorial”, *AI Commun.* 30 (2017) 169–190.
- [71] J. Lu, K. N. Plataniotis, A. N. Venetsanopoulos, “Face recognition using lda-based algorithms”, *IEEE Transactions on Neural Networks* 14(1) (2003) 195–200. doi:10.1109/TNN.2002.806647.
- [72] H. Yu, J. Yang, “A Direct LDA Algorithm for High-Dimensional Data - with Application to Face Recognition”. *Pattern Recognition* 34 (2001) 2067-2070.
- [73] L. J. Cao, K. S. Chua, W. K. Chong, H. P. Lee, Q. M. Gu, “A comparison of PCA, KPCA and ICA for dimensionality reduction in support vector machine”, *Neurocomputing*, 55 (2003) 321 – 336.
- [74] J. Héroult, C. Jutten, B. Ans, “Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé”. In: 10 Colloque sur le traitement du signal et des images, FRA, 1985. GRETSI, Groupe d’Etudes du Traitement du Signal et des Images (1985).
- [75] R. Aziz, C. K. Verma, N. Srivastava, “A Fuzzy Based Feature Selection from Independent Component Subspace for Machine learning Classification of Microarray Data”, *Genomics Data* 8 (2016) 4-15. <https://doi.org/10.1016/j.gdata.2016.02.012>.
- [76] B. C. Z. Honório, A. C. Sanchetta, E. P. Leite, A. C. Vidal, “Independent component spectral analysis”, *Interpretation*, (2)(1) (2014) SA21–SA29. <http://dx.doi.org/10.1190/INT-2013-0074.1>.
- [77] G. R. Naik, D. K. Kumar, “An Overview of Independent Component Analysis and Its Applications”, *Informatica* 35 (2011) 63–81.
- [78] A. Tharwat, “Independent component analysis: An introduction”, *Appl. Comput. Inform.* (2018). <https://doi.org/10.1016/j.aci.2018.08.006>.
- [79] S. Shimizu, P. O. Hoyer, A. Hyvärinen, A. Kerminen, “A linear non-gaussian acyclic model for causal discovery”, *J. Mach. Learn. Res.* 7 (2006) 2003–2030.

- [80] A. Hyvärinen, “Fast and robust fixed-point algorithms for independent component analysis”, *IEEE Trans. Neural Netw.* 10 (1999) 626–634.
- [81] D. Langlois, S. Chartier, D. Gosselin, “An introduction to independent component analysis: Infomax and fastica algorithms, *Tutorials Quantit*”, *Methods Psychol.* 6(1) (2010) 31–38.
- [82] B. A. Pearlmutter, L. C. Parra, “Maximum likelihood blind source separation: A context-sensitive generalization of ica”. In: *Advances in neural information processing systems*, 1997, pp. 613–619.
- [83] T.-W. Lee, “Independent component analysis”. In: *Independent Component Analysis*, Springer, 1998, pp. 27–66.
- [84] A. Hyvärinen, J. Karhunen, E. Oja, “Independent Component Analysis”, Wiley, 2001.
- [85] A. Hyvärinen, E. Oja, “Independent component analysis: algorithms and applications”, *Neural Networks* 13(4) (2000) 411–430.
- [86] Y. Wang, L. Feng, “A new hybrid feature selection based on multi-filter weights and multi-feature weights”, *Appl. Intell.* 49 (2019) 4033–4057. <https://doi.org/10.1007/s10489-019-01470-z>.
- [87] Y. Mei, S. Nguyen, B. Xue, M. Zhang, “An Efficient Feature Selection Algorithm for Evolving Job Shop Scheduling Rules With Genetic Programming”, *IEEE Trans. Emerg. Top. Comput. Intell.* 1(5) (2017) 339–353.
- [88] R. Noori, R. Berndtsson, M. Hosseinzadeh, J. F. Adamowski, M. R. Abyaneh, “A critical review on the application of the National Sanitation Foundation Water Quality Index”, *Environ. Pollut.* 244 (2019) 575–587.
- [89] E. M. Smeti, S. K. Golfinoopoulos, “Characterization of the Quality of a Surface Water Resource by Multivariate Statistical Analysis”, *Anal. Lett.* 49(7) (2016) 1032–1039. <https://doi.org/10.1080/00032719.2015.1045585>.
- [90] H. T. Nguyen, K. Franke, S. Petrović, “Improving Effectiveness of Intrusion Detection by Correlation Feature Selection”, *International Journal of Mobile Computing and Multimedia Communications* 3(1) (2011) 21–34. <https://doi.org/10.4018/jmcmc.2011010102>.

- [91] T. M. Navamani, “Efficient Deep Learning Approaches for Health Informatics”. In: A. K. Sangaiah (Ed.) *Deep Learning and Parallel Computing Environment for Bioengineering Systems*, Academic Press, 2019, pp. 123-137. <https://doi.org/10.1016/B978-0-12-816718-2.00014-2>.
- [92] E. Kanjo, E. M. G. Younis, C. S. Ang, “Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection”, *Inf. Fusion*. 49 (2019) 46–56.
- [93] “RNN (Recurrent Neural Network) Tutorial : TensorFlow Example”, <https://www.guru99.com/rnn-tutorial.html#2>, (accessed 25 January 2020).
- [94] R. Jozefowicz, W. Zaremba, I. Sutskever, “An empirical exploration of recurrent network architectures”. In: *Proceedings of the Thirty-Second International Conference on Machine Learning (ICML-15)* (2015).
- [95] Y. LeCun, Y. Bengio, G. Hinton, “Deep learning”, *Nature* 521 (2015) 436–444. doi:10.1038/nature14539.
- [96] R. DiPietro, G. D. Hager, “Deep learning: RNNs and LSTM”. In: S. K. Zhou, D. Rueckert, G. Fichtinger (Eds.) *Handbook of Medical Image Computing and Computer Assisted Intervention*, Academic Press, 2020, pp. 503-519. <https://doi.org/10.1016/B978-0-12-816176-0.00026-0>.
- [97] R. Pascanu, T. Mikolov, Y. Bengio, “On the difficulty of training recurrent neural networks”. In: *International Conference on Machine Learning (ICML)*, 28, 2013, pp. 1310–1318.
- [98] M. Arjovsky, S. Amar, Y. Bengio, “Unitary evolution recurrent neural networks”. In: *International Conference on Machine Learning (ICML)*, 2016.
- [99] H. Sepp, J. Schmidhuber, “Long Short-Term Memory”, *Neural Comput.* 9(8) (1997) 1735–1780.
- [100] G. Swapna, KP. Soman, R. Vinayakumar, “Automated detection of cardiac arrhythmia using deep learning techniques”. *International Conference on Computational Intelligence and Data Science (ICCIDS 2018)*, *Procedia Comput. Sci.* 132 (2018) 1192–1201.

- [101] K. Greff, R. K. Srivastava, J. Koutnk, B. R. Steunebrink, J. Schmidhuber, “LSTM : a search space odyssey”, *IEEE Trans. Neural Netw. Learn. Syst.* 28(10) (2017) 2222–2232.
- [102] Y. Liu, “Novel Volatility Forecasting Using Deep Learning - Long Short Term Memory Recurrent Neural Networks”, *Expert Syst. Appl.* 132 (2019) 99–109. <https://doi.org/10.1016/j.eswa.2019.04.038>.
- [103] J. Lutsa, F. Ojeda, R. V. de Plas, B. D. Moor, S. V. Huffel, J. A. K. Suykens, “A tutorial on support vector machine-based methods for classification problems in chemometrics”, *Anal. Chim. Acta.* 665 (2010) 129–145. doi:10.1016/j.aca.2010.03.030.
- [104] M. H. Bae, T. Wu, R. Pan, “Mix-ratio sampling: Classifying multiclass imbalanced mouse brain images using support vector machine”, *Expert Syst. Appl.* 37 (2010) 4955–4965.
- [105] M. Ladjal, M. Bouamar, M. Djerioui, Y. Brik, “Performance evaluation of ANN and SVM multiclass models for intelligent water quality classification using Dempster-Shafer Theory”. In: 2nd International Conference on Electrical and Information Technologies (ICEIT’2016) (2016).
- [106] J. H. Min, Y.-C. Lee, “Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters”, *Expert Syst. Appl.* 28 (2005) 603–614. doi:10.1016/j.eswa.2004.12.008.
- [107] M.-H. Horng, “Multi-class support vector machine for classification of the ultrasonic images of supraspinatus”, *Expert Syst. Appl.* 36 (2009) 8124–8133.
- [108] C.-W. Hsu, C.-J. Lin, “A comparison of methods for multi-class support vector machines”, *IEEE Trans. Neural Netw.* 13 (2) (2002) 415–425.
- [109] S. Ding, X. Xu, R. Nie, “Extreme learning machine and its applications”, *Neural Comput. Applic.* 25 (2014) 549–556. DOI 10.1007/s00521-013-1522-8.
- [110] N. Ahmad, T. V. Janahiraman, F. Tarlochan, “Modeling of Surface Roughness in Turning Operation Using Extreme Learning Machine”, *Arab. J. Sci. Eng.* 40 (2015) 595–602. DOI 10.1007/s13369-014-1420-0.
- [111] G. B. Huang, Q. Y. Zhu, C. K. Siew, “Extreme learning machine: theory and applications”, *Neurocomputing* 70 (2006) 489–501. doi:10.1016/j.neucom.2005.12.126.

- [112] F. L. Chen, T. Y. Ou, “Sales forecasting system based on Gray extreme learning machine with Taguchi method in retail industry”. *Exp. Syst. Appl.* 38 (2011) 1336–1345.
- [113] V. Cerqueira, L. Torgo, J. Smailović, I. Mozetič, “A Comparative Study of Performance Estimation Methods for Time Series Forecasting”. In: 2017 IEEE International Conference on Data Science and Advanced Analytics (DSAA) (2018).
- [114] B. Jang, M. Kim, G. Harerimana, S.-u. Kang, J. W. Kim, 2020. “Bi-LSTM Model to Increase Accuracy in Text Classification: Combining Word2vec CNN and Attention Mechanism”, *Appl. Sci.* 10, 5841.
- [115] Y. Li, Z. Zhu, D. Kong, H. Han, Y. Zhao, “EA-LSTM: Evolutionary attention-based LSTM for time series prediction”, *Knowledge-Based Systems* 181 (2019) 104785. <https://doi.org/10.1016/j.knosys.2019.05.028>.
- [116] J. Cao, Z. Li, J. Li, “Financial time series forecasting model based on CEEMDAN and LSTM”, *Physica A: Statistical Mechanics and its Applications* 519 (2019) 127-139. <https://doi.org/10.1016/j.physa.2018.11.061>.
- [117] C. Bergmeir, J. M. Benítez, “On the use of cross-validation for time series predictor evaluation”. *Inf. Sci.* 191 (2012) 192–213.
- [118] C. Bergmeir, M. Costantini, J. M. Benítez, “On the usefulness of cross-validation for directional forecast evaluation”, *Comput. Stat. and Data Anal.* (2014).
- [119] C. Bergmeir, R. J. Hyndman, B. Koo, “A note on the validity of cross-validation for evaluating autoregressive time series prediction”, *Comput. Stat. and Data Anal.* (2017).
- [120] V. Cerqueira, L. Torgo, I. Mozetič, “Evaluating time series forecasting models : An empirical study on performance estimation methods”, (2019). arXiv:1905.11744v1.
- [121] S. Bouktif, A. Fiaz, A. Ouni, M. A. Serhani, 2018. “Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches”, *Energies* 11 (7), 1636. <https://doi.org/10.3390/en11071636>.

**المخلص :** تلعب مراقبة جودة المياه دورًا حيويًا في حماية موارد المياه، الإدارة البيئية، واتخاذ القرار. ومع ذلك، فإن مخاطر التلوث المتزايدة تجعل عملية المراقبة باستعمال الطرق التقليدية أكثر تعقيدًا وتكلفة. في الوقت الحالي، أصبح استخدام العمليات الآلية أمرًا ضروريًا في مجال معالجة المياه بهدف تحقيق مراقبة الجودة وتقليل تكاليف التشغيل. في السنوات الأخيرة، ركزت العديد من الأبحاث على ابتكار وتطوير أساليب جديدة لإجراء عمليات المراقبة التلقائية لجودة المياه. في هذا السياق، أصبح استعمال تقنيات الذكاء الاصطناعي مجالًا رائدًا في المراقبة التلقائية لجودة المياه، من بين هذه التقنيات نذكر : LSTM RNN ، SVM ، ELM تتميز هذه التقنيات عن غيرها بقدرتها العالية في التعلم والتعميم.

الهدف من هذه الدراسة هو تطوير نموذج ذكي لمراقبة جودة المياه في الوقت الحقيقي اعتمادًا على دمج تقنيات استخراج الميزات (PCA، LDA و ICA) والتعلم الآلي (LSTM RNN، SVM و ELM). تم تنفيذ العديد من النماذج وإجراء دراسة مقارنة بينها بهدف اختيار النموذج الأنسب لإمكانية دمج في نظام مراقبة ديناميكي لجودة المياه. تم بناء هذه النماذج باستعمال بيانات المعلمات الفيزيوكيميائية التاريخية التي تم جمعها من محطة سد تيليسديت في البويرة (الجزائر) لمدة ثلاث سنوات. بشكل عام، أظهرت نتائج المحاكات أن النهج المقترح لديه أداء مرضي للغاية. يمكن اعتبار هذا العمل كمساهمة في الحلول المقترحة، لحل المشاكل ذات الأهمية الاستراتيجية الوطنية والدولية، باستخدام الأدوات الحديثة القائمة على التقنيات المتقدمة.

**الكلمات المفتاحية :** المياه النظيفة ، مراقبة جودة المياه ، الذكاء الاصطناعي ، التعلم الآلي ، تقليل الأبعاد ، التصنيف ، سد تيليسديت.

**Abstract :** Water quality control plays a vital role in water resource protection, environmental management, and decision-making. However, the increased risks of contamination make the process of monitoring using traditional methods more complex, difficult, and costly. Nowadays, the use of automated processes has become a necessity in the field of water treatment in order to achieve quality control and reduce operating costs. In recent years, many studies have focused on creating and developing new methods for conducting automatic water quality control and monitoring. In this context, the use of artificial intelligence techniques has become a leading field in automatic water quality monitoring. Among these techniques, we mention LSTM RNN, SVM, and ELM. These techniques are distinguished from others by their high ability to learn and generalize.

The aim of this study is to develop an intelligent model for real-time water quality monitoring based on the integration of feature extraction techniques (PCA, LDA, and ICA) and machine learning techniques (LSTM RNN, SVM, and ELM). Several models were implemented and a comparative study was conducted in order to choose the most appropriate model for the possibility of integrating it into a dynamic water quality monitoring system. These models were built using historical physicochemical parameters data collected from the Tilesdit Dam station in Bouira (Algeria) for a period of three years. In general, the simulation results showed that the proposed approach has a very satisfactory performance. This work can be considered as a contribution to the proposed solutions, to solve problems of national and international strategic importance, using modern tools based on advanced technologies.

**Keywords :** Clean Water, Water Quality Control, Artificial Intelligence, Machine Learning, Dimensionality Reduction, Classification, Tilesdit Dam.

**Résumé :** Le contrôle de la qualité de l'eau joue un rôle essentiel dans la protection des ressources en eau, la gestion de l'environnement et la prise de décision. Cependant, les risques accrus de contamination rendent le processus de surveillance utilisant les méthodes traditionnelles plus complexe, difficile et coûteux. De nos jours, l'utilisation de procédés automatisés est devenue une nécessité dans le domaine du traitement de l'eau afin de réaliser un contrôle de qualité et de réduire les coûts d'exploitation. Ces dernières années, de nombreuses études se sont concentrées sur la création et le développement de nouvelles techniques de contrôle et de surveillance automatiques de la qualité de l'eau. Parmi ces techniques, nous citons LSTM RNN, SVM et ELM. Ces techniques se démarquent de plusieurs avantages par rapport aux autres grâce à leurs capacités d'apprentissage et de généralisation.

L'objectif de cette étude est de développer un modèle intelligent basé sur l'intégration de techniques d'extraction de caractéristiques (PCA, LDA et ICA) et de techniques d'apprentissage automatique (LSTM RNN, SVM et ELM). Cette thèse présente l'application des techniques de l'intelligence artificielle pour améliorer la décision et le diagnostic des systèmes de production et de surveillance automatique de la qualité de l'eau propre. Plusieurs modèles ont été mis en œuvre et une étude comparative a été menée afin de choisir le modèle le plus approprié pour la possibilité de l'intégrer en temps réel dans un système de surveillance dynamique de la qualité de l'eau. Ces modèles ont été construits à partir des données historiques des paramètres physico-chimiques collectées à la station du barrage de Tilesdit à Bouira (Algérie) pendant une période de trois ans. En général, les résultats de la simulation ont montré que l'approche proposée a une performance très satisfaisante. Notre contribution dans ce modeste travail peut alors être considérée comme une solution adéquate qui permet de résoudre des problèmes d'importance stratégique régionale, nationale et internationale liés à la qualité de l'eau, en utilisant des nouveaux outils basés sur des technologies avancées.

**Mots clés :** Eau propre, Contrôle de la qualité de l'eau, Intelligence artificielle, Apprentissage automatique, Réduction de dimensionnalité, Classification, Barrage de Tilesdit.