

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT DE ELECTRONIQUE
N° : 2018/ESEM05/87



DOMAINE : SCIENCE ET TECHNOLOGIE
FILIERE : ELECTRONIQUE
OPTION : SYSTEME EMBARQUEE

Mémoire présenté pour l'obtention
Du diplôme de Master Académique

Par : DJERARDA Souheyla

HEDLI Khaoula

Intitulé

Traitement automatique des eaux basées sur les
techniques d'apprentissage statistique

Soutenu devant le jury composé de :

Mr. BRIK Youcef	Université de M'sila	Président
Mr. DJRIOUI Mohamed	Université de M'sila	Rapporteur
Mr. BOURAS Mounir	Université de M'sila	Examineur

Année universitaire : 2017 /2018

REMERCIEMENTS

Avant toute chose, on remercie Dieu le tout puissant de nous avoir données le courage, la patience et la force durant toutes ces années d'étude.

Nous sommes très reconnaissants à Monsieur DJERIOUI Mohamed et nos remerciements pour nous avoir encadré et en particulier pour son soutien, sa gentillesse, ses encouragements, ses conseils et sa patience pendant la période de la réalisation de ce travail.

Nos sincères remerciements aux messieurs les membres de jury qui nous ont fait l'honneur en acceptant d'examiner ce travail.

Nos remerciements vont aussi aux enseignants du département d'électronique qui ont contribué à notre formation.

Enfin, un remerciement spécial aux étudiants de la 2eme année Master de la spécialité d'électronique spécifiquement système embarquée.

Dédicaces

Je voudrais dédier cet humble travail

à toute ma famille, à ma chère maman et mon cher père

qui nous a quitté à jamais, Qui ont veillé à ce que

je sois ce que je suis devenu maintenant.

À mon binôme khaoula

À mes cher grands parents qui m'ont soutenu et encourager.

À mes belles sœurs, Rym, Assia, Raziqa

À mes frères

À mes amis karima, Najet, Iman, sabira, sara, Ibtissam

À tous les amis de ma promotion

DJERARDA Souheyla

Dédicace

Je voudrais dédie ce modeste travail

*A ma mère pour ses sacrifices en témoignage de tout
mon affection au long de mes études.*

À mon défunt père

A mon binôme Souheyla

A mon fiancé Derri Khaled

A ma sœur Imene que j'adore.

A toute la famille HEDLI.

A toute la famille Blizak

A mes oncles et mes tantes.

A ma cousins Hanan et son mari Yacine

A toutes les amiées

Assma , Lobna , Djohaina

,Nadjwa,Achouak,Souheyla, Bothaina

Hiba ,Ahlem, Oulia,Badra,Asma

HEDLI khawla

DE ABREVIATION.....	VI
LISTE DES FIGURES.....	VIII
LISTE DESTABLEAUX.....	IX
INTRODUCTION GENERALE.....	1

CHAPITRE I

SURVEILLANCE DES PROCEDES DE PRODUCTION D'EAU POTABLE

Introduction.....	3
1. Généralités des eaux.....	4
1.1. Composition chimique.....	4
1.2. Le cycle de l'eau.....	5
1.3. Les ressource utilisées.....	5
1.3.1. Choix de la ressource.....	5
2. L'eau potable.....	6
2.1. Définition de l'eau potable.....	6
2.2. Qualité des eaux de boisson.....	6
2.3. Procédés spécifiques des traitements de potabilisation.....	6
2.4. Les Normes de potabilité.....	7
2.5. Grille normative utilisée pour estimer la qualité de l'eau de boisson	7
3. Analyse physico-chimique.....	8
3.1. Température.....	8
3.2. Conductivité.....	8
3.3. PH.....	9
3.4. Turbidité.....	9

3.5. Le fluor.....	9
3.6. Le fer.....	10
4. Analyse bactériologique.....	10
5. Contrôle sanitaire de l'eau.....	10
6. Importance de l'analyse et du traitement	11
7. Chaîne élémentaire de production d'eau potable	11
8. Les étapes du traitement.....	12
8.3. La clarification.....	13
8.4. La désinfection.....	13
9. Surveillance de la qualité de l'eau de boisson	14
9.1. Les indicateurs de qualité.....	14
10. Surveillance industrielle.....	15
11. 10.1. Les capteurs.....	16
10.1.1. Capteurs physico-chimiques	16
10.1.2. Thermomètre	17
10.1.3. Conductimètre.....	17
10.1.4. PH-mètres.....	18
10.1.5. Le turbidimètre :.....	18
10.1.6. Le Fluorimètre.....	19
10.2. Qualité des capteurs	19
10.2.1. Sensibilité, précision, gamme de mesure.....	19
10.2.2. Fiabilité, environnement et dérive.....	19
10.3. Les capteurs logiciels	20
10.3.1. Définition d'un capteur logiciel (soft sensor).....	21
10.3.2. Les types des capteurs logiciels	21
10.3.2.1. Capteurs logiciels pilotés par les données	21
10.3.2.2. Capteurs logiciels entraînés par le modèle.....	21
10.3.3. Propriétés des capteurs logiciels.....	22
Conclusion.....	23

CHAPITRE II
Techniques d'apprentissage statistique

Introduction.....	24
1. Les réseaux de neurones artificiels (RNA).....	24
1.2. Le neurone biologique.....	25
2. Généralités sur les réseaux de neurone.....	26
2.1 Le neurone formel (artificiel)	26
2.3. Principe du neurone artificiel.....	28
3. Caractérisation d'un RNA	28
3.1. Architecture des réseaux de neurone.....	29
3.1.1. Les réseaux de neurones non bouclés.....	29
3.1.1.1. Réseaux de neurones monocouche.....	29
3.1.1.2. Réseaux de neurones multicouches.....	30
3.1.2. Réseaux de neurones à connexions locales.....	31
3.1.3. Les réseaux de neurones bouclés.....	31
3.2. L'apprentissage des réseaux de neurones	32
3.2.1. Apprentissage supervisé.....	32
3.2.2. Apprentissage non-supervisé	32
3.2.3. Apprentissage par renforcement	34
3.3. Les fonctions d'activation	35
4. Réseau de neurones de type MLP (Multi Layer Perceptron - MLP).....	36
4.2. Processus d'apprentissage dans les réseaux MLP.....	36
4.2.1. L'algorithme de retropropagation.....	36
5. Réseau de neurones de type RBF (Radial Basis Functions).....	39
5.1. Définition d'un réseau RBF	39
5.2. Algorithme d'apprentissage du réseau RBF.....	40
6. Deep Learning	40
6.1. Historique du deep learning.....	41
6.2. Les différents types de modèles.....	42
6.2.1. Les réseaux de neurones convolutifs.....	43
6.2.2. Réseau de neurones récurrents.....	43
6.2.3. Deep générative model.....	44

6.3. Auto encodeur.....	44
6.3.1. Apprentissage	45
Conclusion.....	45

CHAPITRE III

SIMULATION ET RESULTATS

Introduction.....	46
1. Problématique.....	46
1.1 Architecture du système de contrôle et de surveillance.....	46
1.2 Approche utilisée dans la surveillance.....	47
2. Développement d'un capteur logiciel de Chlore.....	48
2.1. Description des données d'entrées.....	48
2.2. Apprentissage et Test.....	49
2.3. Evaluation des performances.....	50
2.3.1. Résultats d'apprentissage.....	50
2.3.2 Résultats de test.....	51
2.4.1 Résultats d'apprentissage.....	52
2.4.2 Résultats de test.....	52
2.5.1. Résultats d'apprentissage.....	53
2.5.2. Résultat de test.....	53
2.6. Etude comparative.....	54
3. Classification multi-classe.....	55
3.1. La station de production d'eau potable Tilesdit.....	56
3.2. Description de la base de données.....	57
3.4. Simulation.....	58
3.4.1. Modèle Neural-MLP.....	58
3.4.2. Modèle Neuronal-RBF.....	58
3.4.2.1. Les résultats d'apprentissage et de test	58
3.4.3. Modèle Deep Learning.....	59

3.4.3.1. Les résultats d'apprentissage et de test.....	59
3.4.4. Etude comparative.....	59
Conclusion.....	61

Liste d'abréviations

pH: potentiel Hydrogène

T°:Température

TU: Turbidité

UV: Ultra violets

Ca²⁺: peroxide de calcium

Mg²⁺ : Magnesium

Na⁺: Sodium

DBO : Demande Biochimique en oxygène

DCO : Demande chimique en oxygène

Fe : Fer

Mn : Maganése

Cu : cuivre

Zn : Zinc

Cd: cadmuim

Pb:plomb

CN: Copernicuim

NTU:Unité néphéométrique

MES:Matiers en suspension

RNA: Réseaux de neurons

C: Conductivité

OD:Oxygène dissous

CO₂:Dioxyde de carbone

RBF:Radial Basis function

UV:Ultra violets

Caco3: Carbonate de calcium

CaO2:peroxide de calcium

Hco3:Bicarbonates

CL: Chloures

PMC: percertron Multicouche

MLP: Multi-layer perceptron

NNCC: le nombre de neurons de couche cachée

t-app:temps d'apprentissage

t-tst: temps de test

EQMA:erreur quaratique

EAM: erreur absolue moyenne

NI: nombre d'itération

R²: coefficient de corrélation

CNN: Réseaux de neurones convolutifs

RNN: Réseaux de neurones reccurents

Liste des figures

Figure .I.1. Cycle des eaux	5
Figure.I.2. Les différentes étapes du traitement de l'eau.....	12
Figure .I.3. Capteur logiciel connecté à l'usine.....	23
Figure .II.1. Neurone biologique.....	26
Figure .II.2 . Neurone formel et neurone biologique.....	27
Figure .II.3. Neurone formel.....	28
Figure .II.4. Schéma d'un réseau de neurones monocouche	30
Figure.II.5. Schéma d'un réseau de neurones non bouclé (Perceptron multicouches).....	31
Figure .II.6 . Schéma d'un réseau de neurones à connexions locales.....	31
Figure .II.7. Schéma de réseau de neurones bouclé.....	32
Figure .II.8 . Schéma bloc de l'apprentissage supervise.....	33
Figure.II.9. Schéma bloc de l'apprentissage supervise.....	34
Figure.II.10. Schéma bloc de l'apprentissage supervise.....	34
Figure .II.11. Exemple d'algorithme de rétropropagation.....	37
Figure .II.12. Structure d'un réseaux RBF.....	39
Figure.II.13. La relation entre l'intelligence artificielle, le machine learning (ML) et le Deep Learning.....	41
Figure.II.14. La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données.....	42
Figure.II.15. Le procède du ML classique comparé à celui du Deep Learning.....	42
Figure.II.16. Exemple image 1000x1000. (à gauche) Le non parameter sharing nous oblige à concevoir une couche cachée de 106 neurones, chaque neurone est connecté à 106 pixels, en tout ça fait 10^{12} paramètres. (à droite) Avec un noyau 10x10 et une couche cachée 10^6 deneurones, le nombre de paramètres est de 10^8	43

Figure.II.17. Structure schématique d'un auto-encodeur avec 3 couches cachées entièrement connectées.....	44
Figure.III.1. Architecture du système de contrôle et de surveillance.....	47
Figure.III.2. L'évolution des cinq paramètres descripteurs.....	49
Figure.III.3. Résultats de test du modèle neuronal-RBF.....	51
Figure.III.4. Résultats de test de modèle neuronal-MLP.....	53
Figure.III.5. L'architecture de Deep Learning utilisé.....	53
Figure.III.6. Résultats de test (Modèle Deep-Learning).....	54
Figure.III.7. Résultats de test des différents modèles.....	55
Figure.III.8. Carte géographique situant le barrage « Tilesdit » [Google Maps].....	56
Figure.III.9. Image représentant le site du barrage « Tilesdit » [Google Earth].....	57
Figure.III.10. Image représentant le site de la station « Tilesdit » [Google Earth].....	57

Liste des tableaux

Tableau .I.1. Grille normative pour estimer la qualité de l'eau en Algérie.....	8
Tableau .I.2. Résumant l'interprétation des valeurs de pH.....	9
Tableau .I.3. Classes de turbidité usuelles (NTU, néphélobimétrie turbidité unit).....	9
Tableau.I.4. Résumé de la caractérisation du milieu (Source Centre thématique francophone de l'eau).....	15
Tableau .I.5. Gamme et calibration de la sonde.....	17
Tableau .II.1. la transition entre le neurone biologique et le neurone formel	28
Tableau. II.2 Différentes fonctions d'activations utilisées dans les RNA.....	35
Tableau.II.3. L'historique du Deep Learning.....	41
Tableau.III.1. Les bases des données.....	49
Tableau. III.2. Résultats d'apprentissage (Modèle neuronal-RBF).....	51
Tableau.III.3. Résultats de test (Modèle neuronal-RBF).....	51
Tableau.III.4. Résultats d'apprentissage (Modèle neuronal-MLP).....	52
Tableau.III.5. Résultats de test (Modèle neural-MLP).....	52
Tableau.III.6. Résultats d'apprentissage (Deep-Learning).....	53
Tableau. III.7. Résultats de test (Modèle Deep-Learning).....	53
Tableau.III.8. Tableau comparatif des caractéristiques des modèle MLP, RBF et Deep Learning.....	54
Tableau.III.9. Résultats d'apprentissage et de test (modèle Neuronal-MLP).....	58
Tableau.III.10. Résultats d'apprentissage et de test (modèle Neuronal-RBF).....	58
Tableau.III.11. Configuration de modèle Deep Learning.....	58
Tableau.III.12. Résultats d'apprentissage et de test (Deep Learning).....	59

INTRODUCTION GENERALE

L'eau est une des ressources les plus importantes de la planète. Par contre, l'alimentation en eau peut être limitée en quantité et/ou en qualité. L'importance de la limitation du point de vue qualitatif est illustrée par le fait que 97 % de l'eau de la Terre est contenue dans des océans et a une teneur en sels d'approximativement 35 000 mg/l ce qui limite énormément l'utilisation de cette immense quantité d'eau comme source d'eau potable. Il est en effet très coûteux de produire de l'eau potable à partir d'eau salée. Il y a 2 % de l'eau de la Terre qui se trouve sous forme de glace et dans les glaciers, tandis que 0,3% se trouvent dans l'atmosphère. Les rivières et les lacs correspondent à seulement 0,1 % de la quantité d'eau totale [1]. Les nappes d'eau souterraine représentent seulement 0,6 % de l'eau de la Terre.

De plus, environ la moitié de l'eau souterraine est localisée à des profondeurs plus grandes que 800m. L'eau est un élément essentiel au fonctionnement des établissements de santé, mais elle peut constituer une source d'infections graves, en cas de contamination, particulièrement pour les patients les plus fragiles. Les principaux risques sanitaires liés à l'utilisation de l'eau dans les établissements de santé doivent donc être identifiés et évalués afin de déterminer les moyens à mettre en oeuvre pour maîtriser ces risques [2]. Pour être consommée sans danger, l'eau doit donc être traitée. Mais la pollution croissante des réserves rend cette opération de plus en plus délicate, obligeant les traiteurs d'eau à constamment innover. Les techniques ont d'ailleurs beaucoup évolué, faisant aujourd'hui du traitement de l'eau une industrie de pointe. La qualité de l'eau est garantie par le contrôle et la surveillance permanente des services qui s'occupent du traitement et de la distribution. Aujourd'hui, l'eau potable représente l'un des produits alimentaires les plus surveillés dans le monde [3].

L'exigence d'une réglementation très stricte des pouvoirs publics est alors bien justifiée. Durant ces dernières années, d'importants efforts ont été déployés dans le développement de méthodes de contrôle et de surveillance automatique dans ce domaine. Les techniques de l'intelligence artificielle qui servent comme outil de base pour l'aide à la décision, présentent une réponse plus élaborée qui peut être obtenue soit à partir de données brutes venant directement des variables de surveillance, soit à partir de données traitées venant des sorties de traitements de bas niveau. Parmi ces techniques, on trouve les réseaux de neurones

artificiels (RNAs) et le Deep Learning, qui se démarquent des autres outils par leur capacité et rapidité d'apprentissage. Présentant des performances dans plusieurs domaines, ils sont utilisés en reconnaissance de formes comme outil de classification ou de régression [2].

La surveillance de potabilité de l'eau peut être mise en pratique selon deux types de méthodes classiques et modernes. Les méthodes classiques sont déterminées par une analyse chimique effectuée au laboratoire, cette méthode nécessite un temps d'analyses relativement important et peut donc être difficilement intégrée dans un système de surveillance et de diagnostic en temps réel de l'unité. En outre les méthodes modernes qui ont l'avantage de pouvoir effectuer un contrôle automatique permanent en temps réel, sont mieux placées pour être une alternative plus efficace. Une surveillance permanente des divers procédés traitement et des relatifs à la qualité de l'eau est devenue nécessaire, ou des systèmes de contrôle automatique infaillibles sont impératifs [4].

Durant ces dernières décennies, des efforts importants ont été réalisés dans le développement des méthodes de contrôle et de surveillance automatique des eaux potables. Ces méthodes dites de haut niveau disposent d'outils qui sont plutôt orientés vers la communication avec un opérateur expert. Celles-ci représentent les techniques de l'intelligence artificielle (IA) qui servent comme outil de base pour l'aide à la décision. Leur réponse est plus élaborée et peut être obtenue soit à partir de données brutes venant directement des variables de surveillance ; soit, à partir de données traitées venant des sorties de traitements de bas niveau [4]. Il est logique de supposer que le problème de contrôle et de surveillance de l'eau brute peut être vu comme un problème de reconnaissance de formes, représentant l'ensemble des observations ou mesure liées aux caractéristiques de celle-ci. Parmi les techniques d'IA connues dans ce domaine, figurent les réseaux de neurones artificiels. Ces techniques se démarquent des autres outils par leur capacité d'apprentissage et de généralisation.

Les différents paramètres physico-chimiques exploités dans le traitement de l'eau, tels que le pH, la température, l'oxygène dissous, la conductivité, et les matières en suspension, sont transformés en signaux électriques à partir d'une fusion des données multi-sensorielle et transmis vers une station de contrôle qui assure l'acquisition et le traitement des données. La technique devant être utilisée au niveau du système de décision doit pouvoir effectuer un contrôle quasi permanent de cette ressource précieuse. De plus, le contrôle et la surveillance d'eaux (classification de données), permettant de déterminer les corrélations existantes entre les variables caractéristiques de l'eau brute puis de ne conserver que les caractéristiques

apportant réellement une information pertinente. C'est qu'on peut utiliser ces sorties comme des variables d'entrée dans un autre système de surveillance [3].

Le travail présenté dans ce mémoire a pour objectif la mise en œuvre de trois méthodes d'apprentissage telles que : Perceptron Multi Couches(PMC), RBF (Radial Basis Function) et Deep Learning, appliquées au domaine de reconnaissance de formes. L'application concerne le contrôle et la surveillance de la potabilité des eaux. Une étude en simulation est effectuée pour valider et évaluer les performances de chacune de ces méthodes dans un but comparatif, permettant un choix décisif de la technique la mieux adaptée.

Le premier chapitre présente une généralité sur les eaux propres. Dans cette section, nous parlerons tout spécialement du processus de traitement des eaux potables, en l'introduisant par des généralités sur leur cycle, leur chaîne de traitement, les ressources naturelles, ainsi que leurs paramètres physico-chimiques. Nous terminerons ce chapitre par les capteurs en général et en particulier les capteurs des paramètres descripteurs de l'eau. Le deuxième chapitre est dédié à une présentation des réseaux de neurones artificiels. On commencera ce chapitre par une présentation de la structure d'un neurone biologique et d'un neurone formel, puis les architectures et l'apprentissage des réseaux PMC, RBF et Deep Learning.

Finalement, dans le dernier chapitre on va présenter la base de données et les différents paramètres caractéristiques de l'eau. On va mettre en œuvre les trois techniques (PMC, RBF et Deep Learning) appliquées au contrôle de la potabilité de l'eau. Une discussion des résultats de simulation obtenus, conclue cette étude pour le choix de la technique la mieux adaptée à l'application. Une conclusion générale en fin de ce travail, retrace les différentes étapes réalisées et souligne les perspectives envisagées.

Introduction

Les hommes, ainsi d'autres êtres vivant, sont très sensibles à la qualité de l'eau consommée. Malheureusement, les ressources en eau potable (sources, nappes, phréatique...) sont assez peu importantes, surexploitées, et souillées par une activité humaine croissante, l'homme a développé des technique de traitement de l'eau pour éliminer les souches de maladies et les contaminants se retrouvant dans l'eau disponibles [5].

Ce premier chapitre est consacré au processus de contrôle de traitement de l'eau brute pour la rendre potable. Il s'agit de donner quelques généralités à propos de cette ressource naturelle qu'est l'eau, ainsi que les outils et moyens mis en œuvre pour son traitement. La chaîne de traitement d'eau potable la plus courante est de ce fait présentée. Les différents paramètres descripteurs de l'eau ainsi que leurs capteurs correspondants sont décrits.

1. Généralités des eaux

1.1. Composition chimique

Dans notre environnement, l'eau est un élément qui joue un rôle majeur aussi bien au point de vue biologique (vie aquatique, source d'eau potable pour l'homme) que du point du vue industriel (eaux de la vague dans les industries métallurgique papeteries eaux de refroidissement dans les centrales thermiques, eaux de production dans les industries agroalimentaires, etc.). Alors il est fondamentale d'exercer un contrôle de la qualité de l'eau. [6], L'eau n'est pas seulement un ensemble de molécules de (deux atomes H_2O d'hydrogène et un atome d'oxygène).

Elle contient en réalité naturellement une très grande variété de matières dissoutes, inertes ou vivantes : des gaz, des substances minérales ou organiques, des microorganismes (bactéries, virus, plancton), ainsi que des particules en suspension (fines particules d'argiles, limons et déchets végétaux). En effet, l'eau est un excellent solvant qui se charge en composés solides ou gazeux tout au long de son cycle, suivant les milieux (rivières, zones humides, roches, atmosphère, etc.) dans lesquels elle circule ou séjourne :

- quand elle tombe en pluie, elle se charge des poussières atmosphériques,
- quand elle ruisselle sur les sols (lessivage),
- quand elle s'infiltré dans le sous-sol, elle se charge des produits d'altération des roches.

La composition chimique de l'eau est ainsi complètement liée aux caractéristiques du bassin versant dans lequel elle opère son cycle (la nature du sol et du sous-sol, les espèces végétales et animales, mais également les activités humaines [7]).

1.2. Le cycle de l'eau

Le cycle de l'eau (ou cycle hydrologique) est un modèle représentant les flux entre les grands réservoirs d'eau liquide, solide ou gazeuse, sur Terre : les océans, l'atmosphère, les lacs, les cours d'eau, les nappes souterraines, les glaciers. Le « moteur » de ce cycle est l'énergie solaire qui, en favorisant l'évaporation de l'eau, entraîne tous les autres échanges [8].

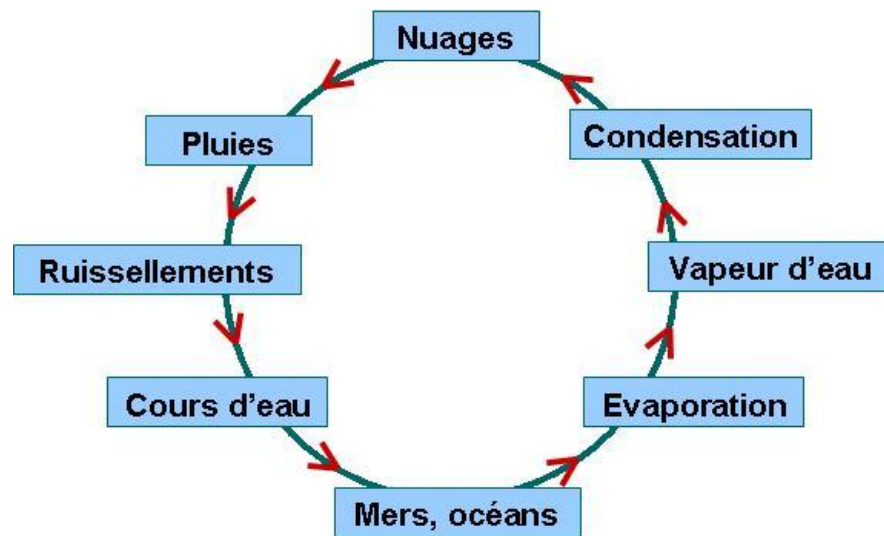


Fig.I.1. Cycle des eaux.

1.3. Les ressources utilisées

1.3.1. Choix de la ressource

L'eau potable est produite à partir d'eaux brutes, superficielles ou souterraines. Les eaux souterraines sont généralement de meilleure qualité que les eaux superficielles.

Le choix de la ressource s'effectue en fonction du couple quantité/qualité.

On prend en compte [5] :

La disponibilité des ressources (y a-t-il une nappe ou un cours d'eau capable de fournir les débits nécessaires à la satisfaction des besoins ?).

La qualité des ressources ; il est évident qu'on utilise en premier lieu les ressources les moins polluées et les moins vulnérables pour la production d'eau potable. Les problèmes de qualité le plus fréquemment rencontrés dans les eaux brutes sont :

- Liés aux caractéristiques naturelles de la ressource comme le fer, le manganèse, le fluor, issus de la dissolution des roches traversées par les eaux d'infiltration, essentiellement dans les eaux souterraines.

- Liés à l'activité humaine, l'agriculture, l'industrie et les rejets d'eaux usées des collectivités.

2. L'eau potable

2.1. Définition de l'eau potable

Plusieurs spécialistes ont définie l'eau par différents manières, mais en général l'eau potable est très malaisée. C'est en effet un terme générique qui ne peut s'appuyer sur un type unique, car toute eau que l'on peut consommer sans danger peut être considérée comme potable. A cette notion de danger potentiel peut se superposer une notion d'agrément vis-à-vis du gout et même de confort (aspect, température). Pour cela, plusieurs spécialistes ont défini l'eau comme suit [9] :

- Une eau potable est une eau devant satisfaire à un certain nombre de caractéristiques la rendant propre à la consommation humaine.
- L'eau qui est fournie par le réseau de distribution doit être conforme aux normes de potabilités (limites), de qualité fixée par la réglementation. Lorsque la limite de qualité est dépassée, l'eau est déclarée non potable.
- On dit qu'une eau est potable lorsque sa consommation n'a pas de danger pour la santé humaine.
- Eau propre à la consommation, signifiant qu'elle ne contient pas de microorganisme

ou autres substances nocives.

- Une eau potable est une eau que l'on peut boire sans risque pour la santé. Peut être consommable, l'eau doit être traitée afin d'éliminer les substances inertes ou vivantes qui peuvent être nocives pour l'organisme. Des normes sont d'ailleurs établies afin de fixer les teneurs limites.

2.2. Procédés spécifiques des traitements de potabilisation

Les procédés spécifiques des traitements de potabilisation sont [10] :

- Sécurité
- De l'approvisionnement
- Station d'alerte en rivière
- Stockage en surface ou en nappe avant traitement
- Des contrôles
- Capteurs automatisés de qualité:
- Matière organique: absorption UV
- MES: turbidité
- Ammonium: capteur spécifique ionique.

2.3. Les Normes de potabilité

Selon l'Organisation Mondiale de la Santé (O.M.S., 1972), l'eau destinée à la consommation urbaine ne doit contenir ni substances chimiques, ni germes nocifs pour la santé. En outre, elle doit être aussi agréable à boire que les circonstances le permettent. Cette définition doit être traduite en termes permettant de déterminer si une eau est potable ou non. C'est l'objet des normes de potabilité, approche quantitative de la notion qualitative de potabilité. Ces normes s'appliqueront à un certain nombre de grandeurs jugées pertinentes en la matière.

2.4. Grille normative utilisée pour estimer la qualité de l'eau de boisson

Cette grille a été établie par l'agence nationale des ressources hydrauliques pour limiter les concentrations des paramètres physico-chimiques dans les eaux de boissons.

Les paramètres	Bonne	Moyenne	Mauvaise	Très mauvaise
Physico-chimiques				
pH	6.5-8.5	6.5-8.5	>6, <9	>5, <9
T°C	25	25-30	30-35	>35
Minéralisation mg/l	300-1000	1000-1200	1200-1600	>1600
Ca ²⁺ mg/l	40-100	100-200	200-300	>300
Mg ²⁺ mg/l	30	30-100	100-150	>150
Na ⁺ mg/l	10-100	100-200	200-500	>500
Chlorures mg/l	10-150	150-300	300-500	>500
Sulfates mg/l	50-200	200-300	300-400	>400
Organiques :				
O ₂ dissous %	>100	100-50	50-30	>30
DBO ₅ mg/l	5	5-10	10-15	>15
DCO mg/l	20	20-40	40-50	>50
Matières organiques	5	5-10	10-15	>15
Composés azotés :				
Ammonium mg/l	0-0.01	0.01-0.1	0.1-3	>3
Nitrites mg/l	0-0.01	0.01-0.1	0.1-3	>3
Nitrates mg/l	0-10	10-20	20-40	>40

Eléments				
toxiques et indésirables :				
Fe mg/l	0-0.5	0.5-1	1-2	>2
Mn mg/l	0-0.1	0.1-0.3	0.3-1	>1
Cr mg/l	0	0-0.05	0.05-0.5	>0.5
Cu mg/l	0-0.02	0.02-0.05	0.05-1	>1
Zn mg/l	0	0-0.5	0.5-1	>1
Cd mg/l	0	0	0-0.01	>0.01
Pb mg/l	0	0	0-0.05	>0.05
F- mg/l	0	0-0.8	0.8-1.5	>1.5
CN- mg/l	0	0	0-0.02	>0.2
Phénols mg/l	0.001-0.002	0.002-0.02	0.02-1	>1

Tab .J.1. Grille normative pour estimer la qualité de l'eau en Algérie [11].

3. Analyse physico-chimique

3.1. Température

La température de l'eau permet de corriger les paramètres d'analyse dont les valeurs sont liées à la température (conductivité notamment). De plus, en mettant en évidence des contrastes de température de l'eau sur un milieu, il est possible d'obtenir des indications sur l'origine et l'écoulement de l'eau. La température doit être mesurée in situ. Les appareils de mesure de la conductivité ou du pH possèdent généralement un thermomètre intégré.

3.2. Conductivité

La conductivité mesure la capacité de l'eau à conduire le courant entre deux électrodes. La plupart des matières dissoutes dans l'eau se trouvent sous forme d'ions chargés électriquement. La mesure de la conductivité permet donc d'apprécier la quantité de sels dissous dans l'eau. La conductivité est également fonction de la température de l'eau : elle est plus importante lorsque la température augmente. Les résultats de mesure doivent donc être présentés en termes de conductivité équivalente à 20 ou 25°C. Les appareils de mesure utilisés sur le terrain effectuent en général automatiquement cette conversion. Ce paramètre doit impérativement être mesuré sur le terrain. La procédure est simple et permet d'obtenir une information très utile pour caractériser l'eau. Comme la température, des contrastes de conductivité permettent de mettre en évidence des pollutions, des zones de mélanges ou d'infiltration. La conductivité est également l'un des moyens de valider les analyses physico-chimiques de l'eau : la valeur mesurée sur le terrain doit être comparable à celle mesurée au laboratoire.

3.3. PH

Le pH (potentiel Hydrogène) mesure la concentration en ions H⁺ de l'eau. Il traduit ainsi la balance entre acide et base sur une échelle de 0 à 14, 7 étant le pH de neutralité. Le pH doit être impérativement mesuré sur le terrain à l'aide d'un pH-mètre ou par colorimétrie.

pH < 5	Acidité forte => présence d'acides minéraux ou organiques dans les eaux naturelles
pH = 7	pH neutre
7 < pH < 8	Neutralité approchée => majorité des eaux de surface
5,5 < pH < 8	Majorité des eaux souterraines
pH = 8	Alcalinité forte, évaporation intense

Tab.I.2. Résumant l'interprétation des valeurs de pH.

3.4. Turbidité

La mesure de la turbidité permet de préciser les informations visuelles sur l'eau. La turbidité traduit la présence de particules en suspension dans l'eau (débris organiques, argiles, organismes microscopiques...). Les désagréments causés par une turbidité auprès des usagers sont relatifs car certaines populations sont habituées à consommer une eau plus ou moins trouble et n'apprécient pas les qualités d'une eau très claire. Cependant une turbidité forte peut permettre à des micro-organismes de se fixer sur des particules en suspension. La turbidité se mesure sur le terrain à l'aide d'un turbidimètre.

NTU < 5	Eau claire
5 < NTU < 30	Eau légèrement trouble
NTU > 50	Eau trouble

Tab.1.3. Classes de turbidité usuelles (NTU, néphélogétrie turbidité unit).

3.5. Le fluor

Les sources principales de fluor dans les eaux souterraines sont les roches sédimentaires (fluorapatite des bassins phosphatés par exemple) mais également les roches magmatiques et certains filons. L'exposition aux fluorures contenus dans l'eau de boisson dépend beaucoup des circonstances naturelles. La concentration des eaux brutes est normalement inférieure à 1,5 mg/l, mais dans les régions où se trouvent des minéraux riches en fluorures, l'eau

souterraine peut en contenir jusqu'à 10 mg/l. Le fluor est reconnu comme un élément essentiel pour la prévention des caries dentaires (dentifrices fluorés).

3.6. Le fer

Le fer est l'un des métaux les plus abondants de la croûte terrestre. On le retrouve dans les eaux douces naturelles à des concentrations allant de 0,5 à 50 mg/l. Le fer est un élément nutritionnel essentiel pour l'homme. Les besoins quotidiens dépendent de l'âge, du sexe, de l'état physiologique et de la biodisponibilité du fer dans le composé considéré. Il varie de 10 à 50 mg/jour environ.

4. Analyse bactériologique

Si l'aspect quantitatif de l'eau est primordial, il ne faut pas négliger l'aspect qualitatif. La priorité reste les risques biologiques. Les conséquences de certaines contaminations, en particulier les contaminations bactériologiques, sont telles que les mesures préventives et les traitements correctifs sont d'une importance capitale et ne doivent faire l'objet d'aucun compromis. L'analyse bactériologique permet de mettre en évidence la pollution fécale de l'eau. Elle représente également un bon moyen pour contrôler l'efficacité des mesures de protection ou de traitement. Elle doit être utilisée comme un outil complémentaire de l'enquête sanitaire. En effet, elle n'est que la photographie de la qualité de l'eau au moment du prélèvement et elle n'a donc pas valeur dans le temps et doit être interprétée au regard de l'enquête sanitaire [11].

5. Contrôle sanitaire de l'eau

La qualité de l'eau potable est soumise à deux types de contrôle, que son distributeur soit public ou privé :

Un contrôle officiel, ponctuel, qui relève de la compétence des pouvoirs publics (agence régionale de santé). Il s'agit là du contrôle réglementaire fondamental ; il porte sur l'ensemble du système de distribution : points de prélèvement, stations de traitement, réservoirs et réseaux de distribution ainsi que les centres aquatique (piscines...), les campings et les restaurants. Les échantillons d'eau prélevés aux différents points de contrôle sont analysés par des laboratoires agréés par le ministère chargé de la Santé. La nature et la fréquence de ces analyses sont fixées par le ministère de la santé. Elles dépendent notamment de la taille de la collectivité desservie : plus celle-ci est grande, plus les contrôles sont fréquents. Suivant le nombre de châteaux d'eau ou stations d'approvisionnement d'eau potable. Cela influence sur la nature et la fréquence des analyses. Une auto-surveillance permanente par les exploitants de leurs services de distribution (régies municipales ou sociétés déléguées).

Bien que peu de municipalités le pratiquent en dehors des prélèvements obligatoires, qui incombent financièrement aux communes. La qualité du réseau influe aussi celle de l'eau selon son intégrité : Quand un réseau fuit, en cas de dépression, c'est l'eau de la nappe superficielle, éventuellement polluée ou chargée de microbes indésirables qui peut pénétrer dans le réseau [3].

6. Importance de l'analyse et du traitement

Une analyse régulière de l'eau est importante pour les raisons suivantes :

- Elle permet de définir les problèmes existants.
- Elle garantit une eau qui convient à l'utilisation prévue.
- Elle garantit une eau potable sûre.
- Elle permet de vérifier l'efficacité des procédés dans un système de production.

La qualité d'une réserve d'eau peut changer au fil du temps et même subitement. Si l'apparence, l'odeur et le goût de l'eau restent les mêmes, le changement de qualité risque de passer inaperçu. La seule façon de connaître la salubrité de l'eau potable, est de la faire analyser. Comme les bactéries, les parasites et les virus nuisibles sont invisibles à l'œil nu, une eau au goût et à l'apparence agréables n'est pas forcément potable. Ces microbes, qui vivent parfois dans l'eau souterraine et de surface, risquent de causer rapidement des maladies chez les humains qui consomment l'eau sans la traiter adéquatement. Certains contaminants chimiques que l'on retrouve dans les réserves d'eau peuvent causer des problèmes de santé à long terme, qui n'apparaissent que des années après la consommation. Une analyse fréquente de l'eau permet de déterminer le niveau de salubrité de l'eau et de vérifier si le système de traitement a atteint un degré de purification satisfaisant. Plusieurs analyses disponibles sont utiles pour déterminer la salubrité et la sûreté des réserves d'eau. L'analyse de base de l'eau potable comprend plusieurs aspects d'analyse tels que celui des bactéries coliformes, des nitrates, du pH, du sodium, du chlorure, du fluorure, des sulfates, du fer, du manganèse, des matières totales dissoutes et celui de la dureté [7].

7. Chaîne élémentaire de production d'eau potable

L'industrie de l'eau a une pression croissante pour produire une eau traitée de plus grande qualité à un coût plus faible. Les eaux à visée de potabilisation pour la consommation humaine sont de différentes natures. Les eaux souterraines constituent 22 % des réserves d'eau douce. Elles sont généralement d'excellente qualité physico-chimique et bactériologique. Néanmoins, les terrains traversés en influent fortement la minéralisation. Les eaux de surface se répartissent en eaux courantes ou stockées (stagnantes). Elles sont généralement riches en gaz dissous, en matières en suspension et organiques, ainsi qu'en plancton. Elles sont très sensibles à la pollution minérale et organique de type nitrate et

pesticide d'origine agricole. Dans cette section, nous parlerons plus spécialement de traitement des eaux de surface, mais il est certain que certaines eaux souterraines doivent également être traitées. Suivant les circonstances, ces deux types de traitement sont semblables ou différents, mais de toute façon ils présentent des points communs. Le principal objectif d'une station de production d'eau potable est de fournir un produit qui satisfait à un ensemble de normes de qualité à un prix raisonnable pour le consommateur [3].

8. Les étapes du traitement

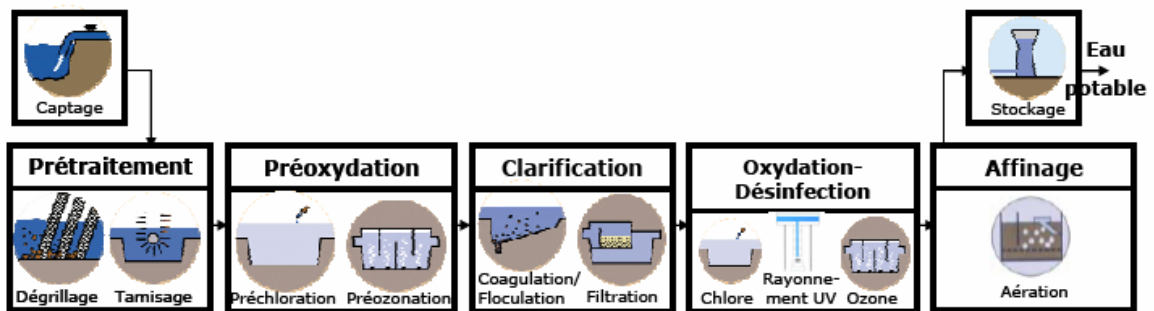


Fig.1.2. Les différentes étapes du traitement de l'eau [12].

8.1. Prétraitement

Avant de procéder au traitement proprement dit, l'eau va subir différents prétraitements (physiques, chimiques ou mécaniques). Il s'agit par exemple de :

- retenir à l'aide de grilles des déchets solides plus ou moins volumineux tels que des pierres, branches, feuilles, etc.
- ajouter des produits chimiques pour prévenir ou limiter la croissance d'algues ;
- effectuer une sédimentation de matériaux légers tels que sable, gravier, ...

8.2. Peroxydation

L'oxydation est une opération essentielle à tout traitement des eaux. Elle est toujours incluse en fin de filière au niveau de la désinfection.

À l'issue du prétraitement, on a une eau relativement propre mais qui contient encore des particules colloïdales en suspension. Celles-ci n'ont en elles-mêmes rien de dangereux. Il nous arrive souvent de consommer de l'eau en contenant : le thé, le café, le vin ou le lait qui sont chargés en matières organiques, mais qui s'oxydent spontanément en présence d'air. On va les détruire dans la mesure du possible par une oxydation. Celle-ci peut être faite de trois façons différentes :

- Ajout de Chlore (pré-chloration)
- Ajoute de dioxyde de chlore
- Ajoute d'ozone (pré-ozonation)

On préfère utiliser le dioxyde de chlore qui coûte plus cher mais qui n'a pas les inconvénients de l'oxydation par le chlore cités ci-dessus. Ce type de traitement est cependant réservé à des cas spécifiques. En effet, l'utilisation du dioxyde de chlore présente, lui aussi, des inconvénients non négligeables comme sa décomposition à la lumière, ce qui entraîne une augmentation du taux de traitement à appliquer en période d'ensoleillement.

8.3. La clarification

La clarification est l'ensemble des opérations permettant d'éliminer les matières en suspension *MES* (minérales et organiques) d'une eau brute ainsi que des matières organiques dissoutes. Suivant les concentrations de l'un et de l'autre des différents polluants, on peut être amené à pratiquer des opérations de plus en plus complexes qui vont de la simple filtration avec ou sans réactif jusqu'à la coagulation – floculation – décantation ou flottation – filtration.

La clarification comprend les opérations suivantes :

- Coagulation
- Floculation
- Filtration

La coagulation est l'une des étapes les plus importantes dans le traitement des eaux de surface. 90% des usines de production d'eau potable sont concernées. La difficulté principale est de déterminer la quantité optimale de réactif à injecter en fonction des caractéristiques de l'eau brute.

8.4. La désinfection

La désinfection est l'étape ultime du traitement de l'eau de consommation avant distribution. Elle permet d'éliminer tous les micro-organismes pathogènes présents dans l'eau. Il peut cependant subsister dans l'eau quelques germes banals, car la désinfection n'est pas une stérilisation.

Le principe de la désinfection est de mettre en contact un désinfectant à une certaine concentration pendant un certain temps avec une eau supposée contaminée. Cette définition fait apparaître trois notions importantes : les désinfectants, le temps de contact et la concentration résiduelle en désinfectant. Une bonne désinfection via les réactifs oxydants demande la combinaison d'une concentration C avec un temps de contact T ; c'est le facteur $C \cdot T$ (mg.min/L). Cette valeur varie avec les micro-organismes concernés, le type de désinfectant et la température.

8.5. Affinage

Le traitement final traite de la mise à l'équilibre calco-carbonique. L'eau suit un cycle naturel dans lequel les éléments chimiques qu'elle contient évoluent. L'eau de pluie contient naturellement du dioxyde de carbone (CO_2). Quand celle-ci traverse les couches d'humus, riches en acides, elle peut s'enrichir fortement en CO_2 . Lors de sa pénétration dans un sol calcaire, c'est-à-dire riche en carbonate de calcium ($CaCO_3$), elle se charge en calcium CaO_2^+ et en ions bicarbonates HCO_3^- . En fait, le calcium est dissous par l'eau chargée en CO_2 . On dit qu'elle est entartrant ou incrustante. En revanche, quand l'eau de pluie traverse une roche pauvre en calcium (région granitique), elle reste très chargée en CO_2 dissous. Cette eau est, en générale, acide. On dit qu'elle est agressive.

8.6. Coagulation-Floculation

Le mot coagulation vient du latin coagulare qui signifie « agglomérer ». La couleur et la turbidité d'une eau de surface sont dues à la présence de particules de très faible diamètre : les colloïdes. Leur élimination ne peut se baser sur la simple décantation. En effet, leur vitesse de sédimentation est extrêmement faible. Le temps nécessaire pour parcourir 1 m en chute libre peut être de plusieurs années.

La coagulation et la floculation sont les processus qui permettent l'élimination des colloïdes. La coagulation consiste à les déstabiliser. Il s'agit de neutraliser leurs charges électrostatiques de répulsion pour permettre leur rencontre. La floculation rend compte de leur agglomération en agrégats éliminés par décantation et/ou filtration.

9. Surveillance de la qualité de l'eau de boisson

La surveillance des analyses est de plus en plus fondamentale pour garantir la qualité de l'eau. Cependant, avant que les résultats ne soient disponibles, l'eau a généralement été fournie et peut avoir été consommée.

9.1. Les indicateurs de qualité

Les moyens disponibles sur le terrain pour estimer la qualité de l'eau sont les suivants :

- l'enquête sanitaire, complétée par l'analyse bactériologique ;
- les analyses physico-chimiques.

Le choix de la méthode s'effectue en fonction de l'objectif poursuivi :

- recherche de pollution par les matières fécales ;
- caractérisation de l'eau avant de la traiter, ou dans le but de déterminer si le traitement est efficace ; caractérisation du milieu: connaître la qualité d'une mare ou d'un cours

d'eau avant de l'exploiter pour l'approvisionnement d'une installation, d'un camp de réfugiés ou d'un village ou encore connaître la signature chimique de l'eau des forages afin de mieux comprendre le système aquifère, ou encore pour savoir si l'eau peut être utilisée pour la consommation.

Objectifs	Indicateurs
Recherche d'une pollution fécale	Enquête sanitaire Analyse bactériologique
Caractérisation du milieu « Eau souterraine »	<ul style="list-style-type: none"> • Conductivité • Température • pH • Cations (calcium, magnésium, potassium, sodium) • Anions (chlorures, sulfate, nitrate, alcalinité) • Eléments traces (fer, manganèse, fluorure.)

Tab.I.4. Résumé de la caractérisation du milieu (Source Centre thématique francophone de l'eau).

10. Surveillance industrielle

Quand on parle de surveillance des eaux potables, il s'agit en fait de connaître l'état de l'eau en continu (à chaque instant) à partir des différents paramètres ayant trait à sa qualité. Traditionnellement, on procède généralement à un certain nombre de mesures utiles des différents paramètres de l'eau brute pour le test de sa qualité tels que : le contrôle bactériologique, le contrôle de désinfection, et le contrôle physico-chimique (pH, température, turbidité, conductivité, oxygène dissous,...), et pour décider après sur son état propre, et par la suite chercher les techniques et méthodes pour la rendre potable. Ces méthodes sont déterminées à l'aide d'un essai expérimental appelé *Jar-test*. La dose optimale du coagulant recherchée est déterminée en fonction de la qualité des différentes eaux comparées. En général dans les usines importantes, un seul essai est effectué par jour. L'opérateur fera un nouvel essai entre temps pour changer la dose du coagulant uniquement si la qualité de l'eau traitée se dégrade. L'inconvénient de cette technique est qu'elle nécessite de façon non stop des interventions et des déplacements sur site de l'opérateur. Cette technique ne permet pas de suivre finement l'évolution de la qualité de l'eau brute et aura le désavantage d'avoir un

temps de réponse relativement long. En voici tout l'intérêt de disposer d'un contrôle automatique de ce procédé pour une meilleure efficacité de traitement et une réduction des coûts d'exploitation. Le contrôle de l'eau au niveau des usines de production doit se faire de façon immédiate en se basant sur une surveillance continue des paramètres descripteurs de la qualité à travers toute une chaîne de traitement qui assure à la fois la surveillance et le contrôle.

L'automatisation couplée à un stockage d'informations, permet d'envisager des études statistiques de données recueillies ouvrant la voie à des études de modélisation et donc d'optimisation des procédés de traitement. Plus récemment, l'automatisation et la supervision par ordinateur ont conduit à une augmentation du confort en permettant une meilleure maîtrise même à distance d'un grand nombre d'informations, ce qui permet de simplifier les tâches d'exploitation, de surveillance, de maintenance et de gestion. L'utilisation des techniques issues du domaine de l'intelligence artificielle apparaît comme la principale alternative pour aborder ces problèmes lorsqu'il est nécessaire de prendre en compte l'intervention des experts du domaine ou de traiter l'information de nature qualitative.

Généralement un niveau supérieur comme la supervision, est supposé à la boucle de commande afin d'assurer des conditions d'opération pour lesquelles les algorithmes d'estimation et de commande soient efficaces pour la surveillance des différentes installations et procédés de production d'eau potable. Parmi les tâches spécifiques de la supervision se trouvent la détection des défaillances, le diagnostic, le changement des consignes et la reconfiguration de la loi de commande. Ces tâches sont réalisées typiquement par des opérateurs humains qui prennent des décisions après avoir évalué l'état du procédé à partir des variables recueillies à travers des capteurs physiques spécifiques, en utilisant leur connaissance d'expert [12].

10.1. Les capteurs

Le capteur est le dispositif qui soumis à l'action d'un mesurande non électrique présente une caractéristique de nature électrique (charge, tension, courant ou impédance) [12]. Celui-ci est possible en utilisant un élément appelé "corps d'épreuve" ou "transducteur". Le principe consistant à faire correspondre une grandeur d'entrée à une grandeur de sortie selon un conditionnement déterminé [13].

10.1.1. Capteurs physico-chimiques

Capteurs physico-chimiques sont des capteurs de type analogique disposant d'afficheurs numériques et reliés au système de supervision/recueil de données. L'ensemble de ces capteurs inclut [13]:

- une sonde multi-paramètres (T° , pH, conductivité, O_2 , potentiel Redox),

- un turbidimètre autonettoyant (information générale sur la qualité de l'eau),
- deux fluorimètres (détection des hydrocarbures, solvants, alcools),
- un analyseur Nitrate/Ammonium .

La sonde multi-paramètres (T° , pH, conductivité, O_2 potentiel Redox) Ce transmetteur multi-paramètres dispose de réactifs, d'électrodes et d'un thermomètre permettant d'enregistrer les mesures correspondantes aux trois grandeurs recueillies par ce multi-capteur. Les gammes de mesures sont représentées sur le tableau suivant:

Grandeur (résolution et précision)	Gamme	Calibration
pH (0,1)	2,00 à 12,00	4-20mA
$^\circ\text{C}$ (1 $^\circ\text{C}$)	0 $^\circ\text{C}$ à 50 $^\circ\text{C}$	4-20mA
Conductivité (salinité)	0-1999 $\mu\text{S}/\text{cm}$	4-20mA
Oxygène dissous	0-60 mg/L	4-20mA
Redox (100mV)	0 à 400mV	4-20mA

Tab.1.5. Gamme et calibration de la sonde.

Les gammes peuvent être réglées à 20% au-delà ou en dessous des valeurs seuils.

Les trois grandeurs sont continuellement affichées sur leur afficheur respectif. Une alarme peut être réglée en fonction d'une valeur pré-programmable. Les données 4-20 mA sont transmises vers le superviseur à travers la centrale d'acquisition [13].

10.1.2. Thermomètre

La température de l'eau est généralement mesurée à l'aide d'un thermomètre à résistance afin de pouvoir être transmise à distance. On utilise la croissance de la résistivité des métaux avec la température. Le courant électrique traversant une telle résistance alimentée sous tension sera donc inversement proportionnel à la température du milieu environnant [13].

10.1.3. Conductimètre

L'appareil servant à évaluer la conductivité spécifique de l'eau s'appelle conductimètre. Il consiste à mesurer l'intensité du courant électrique recueilli aux bornes de deux électrodes de géométries connues, plongées dans l'eau et soumises à une différence de potentiel alternatif, dont la fréquence doit être d'autant plus élevée que la concentration en acides, sels ou bases dissous est grande, pour éviter les phénomènes de polarisation. Le courant électrique mesuré est proportionnel à la concentration d'ions dans l'eau ; plus il est élevé, plus il y a d'ions dans l'eau. Le résultat se traduit en micro- Siemens par centimètre ($\mu\text{S}/\text{cm}$) à une température normalisée de 25 $^\circ\text{C}$ [13].

10.1.4. PH-mètres

Plusieurs méthodes sont possibles pour mesurer le pH d'une eau. Les appareils électroniques (pH-mètres) permettent une mesure assez précise de la valeur du pH, à condition d'être correctement étalonnés (réglés). Son fonctionnement est basé sur le rapport qui existe entre la concentration en ions H_3O^+ (définition du pH) et la différence de potentiel électrochimique qui s'établit dans le pH-mètre une fois plongé dans l'eau. Celui-ci est constitué de deux électrodes, l'une standard dont le potentiel est constant et connu (appelée électrode de référence), l'autre à potentiel variable (fonction du pH, appelée électrode de verre). Ces deux électrodes peuvent être combinées ou séparées. Il suffit donc de relier ces bornes à un voltmètre pour connaître la valeur du pH. En pratique, les électrodes sont réunies pour former une sonde [14].

La teneur en oxygène dissous (OD) des eaux d'un lac est mesurée à l'aide d'une sonde munie d'une électrode sensible à cette molécule. L'oxygène dissous est généralement mesuré dans les parties les plus profondes du lac, à chaque mètre en partant de la surface du lac jusqu'au fond. L'ampèremètre est utilisé industriellement en traitement des eaux pour la mesure en continu de la concentration en agents oxydants et met en œuvre une méthode simplifiée d'analyse par ampérométrie. La cellule de mesure, qui est alimentée à débit constant en eau à analyser, comporte une cathode inattaquable, par exemple en platine, et une anode qui peut-être en cuivre, en cadmium, en argent, etc. En l'absence d'agent oxydant, la pile ainsi formée est polarisée et n'est traversée que par un courant très faible. Sa dépolarisation et, par conséquent, l'intensité du courant qu'elle débite sont sensiblement proportionnelles à la concentration de l'agent oxydant qui vient se réduire à la cathode. On mesure ainsi la concentration en chlore, ozone et oxygène d'une eau. L'inconvénient de ces appareils réside dans le fait qu'ils mesurent la somme des agents oxydants et qu'ils ne peuvent être vraiment utilisés que dans le cas où un seul corps se trouve en solution à concentration variable. L'effet d'un autre corps, éventuellement présent à concentration constante, peut être annulé par action sur le zéro de l'appareil. La concentration en oxygène dissous dans l'eau est communément exprimée en milligrammes par litre (mg/l) ou en pourcentage de saturation.

10.1.5. Le turbidimètre :

La mesure de la turbidité de l'eau correspond à une mesure optique des particules en suspension dans l'eau qui lui donnent un aspect trouble. L'unité employée est appelée unité néphélométrique de turbidité (NTU). Les particules sont d'origines diverses : argiles, limons, organismes microscopiques, dépôts dans les canalisations, corrosion, etc. Le turbidimètre mesure alors la quantité de lumière diffusée par un échantillon d'eau brute du fait de la présence de particules dans l'eau [14].

10.1.6. Le Fluorimètre

Cet appareil permet de mesurer le dosage de la concentration d'une substance par la mesure de l'intensité de son rayonnement de fluorescence. L'appareil est composé de deux sondes, l'une pour les hydrocarbures et l'autre pour la chlorophylle. Le principe de mesure est le même dans les deux cas, il s'agit de la détection par fluorescence. Celle-ci est produite par l'action d'un faisceau de lumière monochromatique, qui en pénétrant dans un échantillon provoque une émission lumineuse à une longueur d'onde plus grande [13].

10.2. Qualité des capteurs

Nous allons maintenant aborder les problèmes liés à la qualité et à l'utilisation en continu de ces différents capteurs. En effet, pour que le fonctionnement de l'ensemble d'une boucle de mesure soit correct, il est essentiel de s'assurer de la compatibilité de chacun des instruments de la boucle et en particulier du capteur. L'information ainsi délivrée, surtout si elle est utilisée dans une régulation automatique ou comme entrée d'un modèle, doit être la plus représentative possible de la valeur vraie du paramètre mesuré et être très fiable [3].

10.2.1. Sensibilité, précision, gamme de mesure

De nombreux facteurs conditionnent l'écart entre la valeur du paramètre mesuré et l'information délivrée. Le premier facteur est la précision du capteur. Celle-ci, exprimée en pourcentage, est le quotient de l'incertitude de la valeur obtenue par l'étendue de mesure pour des conditions de mesure données. La précision du capteur est fonction du processus de mesure mais aussi des corrections annexes qui y sont apportées. Une bonne précision finale dépend d'une bonne corrélation entre une caractéristique ou un phénomène annexe, pouvant être mesuré avec une bonne précision, et le phénomène à mesurer. Un autre facteur peut être l'existence d'erreurs systématiques dues à un étalonnage incorrect ou trop peu fréquent du capteur. Les erreurs accidentelles peuvent également être causées par des signaux parasites, ou des absences de correction de température, de pression, etc. La sensibilité initiale d'un appareil de mesure est un autre facteur à prendre en compte. Celle-ci est la valeur minimum du paramètre à mesurer en dessous duquel l'appareil ne réagit pas. La sensibilité en fonctionnement est la plus petite variation du paramètre mesuré décelable par la mesure. Elle n'est pas nécessairement constante dans toute la gamme de mesure. Il faut enfin tenir compte de la gamme de mesure du capteur, qui correspond aux valeurs de seuils au delà desquels la précision et la sensibilité du capteur se dégradent [14].

10.2.2. Fiabilité, environnement et dérive

La fiabilité est définie comme la capacité du capteur à fonctionner correctement, c'est-à-dire à fournir des données avec la précision annoncée. Elle dépend naturellement de la qualité

de conception du matériel qui doit être robuste et avoir été entretenu conformément aux spécifications du constructeur. Mais elle dépend également de son adaptation à l'environnement dans lequel il va se trouver. Les contraintes des capteurs concernant la gestion de l'eau sont principalement l'humidité et la nature de l'eau. L'humidité peut provoquer de la condensation dans les boîtiers du matériel. Ceux-ci doivent être étanches, des submersions étant toujours possibles, et doivent comporter des dispositifs éliminant la condensation. Cette atmosphère humide peut également provoquer des courts circuits au niveau des câbles de jonction ou d'alimentation. La nature de l'eau, notamment celle des rivières, peut perturber les capteurs immergés avec des dépôts en en modifiant les réactions. C'est en particulier le cas de nombreuses sondes dont le nettoyage doit être effectué très régulièrement car ces dépôts provoquent une dérive du capteur.

C'est le principal défaut de ce type de capteur dont la surveillance doit être constante, les dispositifs de nettoyage automatique sous forme de brosses ou de rétro-lavage de la sonde n'étant pas toujours efficaces. C'est l'une des raisons pour lesquelles certains de ces capteurs opèrent à partir de bacs extérieurs auxquels on amène l'eau à analyser, notamment dans les stations d'analyse ou d'alerte en rivière. Le problème est alors celui de la prise d'eau, de l'entretien de la crépine d'aspiration et de la bonne représentativité de l'eau dans le bac.

En conclusion, pour tirer pleinement parti des avantages des capteurs de mesure et de l'instrumentation associée, il est indispensable d'accepter certaines contraintes telles que le nettoyage des sondes de mesures, l'étalonnage régulier, etc. Malgré ces précautions, certains facteurs peuvent encore perturber l'information délivrée par les capteurs. Il sera donc indispensable d'avoir une phase de validation de ces informations avant toute utilisation dans une boucle de régulation ou en entrée d'un modèle [14].

10.3. Les capteurs logiciels

Les usines de traitement industriel sont généralement fortement instrumentées avec un grand nombre de capteurs. L'objectif principal des capteurs est de fournir des données pour la surveillance et le contrôle des processus. Mais il y a environ deux décennies, les chercheurs ont commencé à utiliser les grandes quantités de données mesurées et stockées dans l'industrie des procédés en construisant des modèles prédictifs basés sur ces données. Dans le contexte de l'industrie des procédés, ces modèles prédictifs sont appelés capteurs logiciel. Ce terme est une combinaison des mots «logiciel», car les modèles sont généralement des programmes informatiques et des «capteurs», car les modèles fournissent des informations similaires à celles de leurs équivalents matériels [15]. Des capteurs logiciels ont été signalés pour compléter l'instrument en ligne mesures pour la surveillance et le contrôle des processus. Tous les deux des capteurs logiciel basés sur des modèles et des données ont été développés [16].

Et aussi Les capteurs logiciel ont été largement étudiés et utilisés comme des systèmes de détection inférentielle pour fournir des estimations en ligne des variables des processus [17].

10.3.1. Définition d'un capteur logiciel (soft sensor)

Le terme (capteur logiciel) combine les mots "logiciel", parce que les modèles d'évaluation des signaux de capteurs sont généralement mis en œuvre dans les programmes informatiques, et les "capteurs", parce que ces modèles fournissent des informations similaires aux capteurs matériels ".

Le capteur logiciel est un outil précieux dans de nombreux domaines industriels. Il est utilisé pour résoudre un certain nombre de problèmes tels que les systèmes back-up, l'analyse d'hypothèses, la prévision en temps réel pour le contrôle de l'usine et les stratégies de diagnostic de défauts.

Les capteurs logiciels sont un sous-groupe de modèles prédictifs empiriques / mécaniques qui estiment les variables cibles en fonction de leur corrélation avec le processus facilement disponible variables indépendantes. Les variables difficiles à mesurer sont appelées réponses, variables dépendantes, les variables cibles, les variables primaires ou la sortie du modèle; tandis que les capteurs logiciels faciles à mesurer dans les procédés industriels [16].

10.3.2. Les types des capteurs logiciels

10.3.2.1. Capteurs logiciels pilotés par les données (Data-driven Soft Sensors)

Ce sont des modèles basés sur des données de la boîte noire, qui décrivent les conditions réelles d'une plante, induite par des données de mesure d'entrée-sortie observées. Contrairement aux capteurs mous pilotés par les modèles, qui seront décrits ci-après, ils ressemblent traiter les états de façon plus réaliste et décrire les relations entre les entrées et les sorties plus précisément. Comme leur nom l'indique, ils sont basés sur des données mesurées, qui peut être soit prélevé sur l'installation pour laquelle le capteur souple est développé, soit à partir d'expériences spécialement conçues Les données [18].

10.3.2.2. Capteurs logiciels entraînés par le modèle (Model Driven Soft Sensors)

Ce sont les premiers modèles de principe (FPM) qui se concentrent sur l'état du processus, décrivant leurs origines physiques et chimiques. Ce type de capteur est principalement basé sur la dérivation d'équations qui peut décrire les caractéristiques du

processus, et à cause de cela, ils sont aussi dénommés modèles basés sur la connaissance ou modèles de boîte blanche [17].

10.3.3. Propriétés des capteurs logiciels

Les capteurs logiciels offrent un certain nombre de propriétés intéressantes [20] :

- Ils représentent une alternative à faible coût aux capteurs physiques. En effet, la disponibilité des analyseurs en ligne et des systèmes numériques qui sont à la fois utilisés pour la surveillance et le contrôle, donnent aux concepteurs et aux opérateurs les outils nécessaires à la conception et la mise en œuvre des capteurs logiciels, sans augmenter les coûts initiaux ;
- Ils permettent la réalisation de réseaux de surveillance plus complets;
- Ils peuvent travailler en parallèle avec des capteurs physiques, donnant des informations utiles pour les tâches de détection de défaut, permettant ainsi la réalisation de processus plus fiables ;
- Ils peuvent facilement être implantés dans des micro-informatiques et réajustés lorsqu'il y a un changement dans les paramètres du système ;
- Ils permettent d'estimer en temps réel des données et de diminuer les retards introduits par des capteurs physiques lents, améliorant ainsi la performance des stratégies de contrôle. Les capteurs logiciels peuvent être utilisés en tant que :
 - ❖ Back-up des appareils de mesure : Le back-up des instruments de mesure est une application typique de capteurs logiciels : un capteur logiciel est dans ce cas spécialement conçu pour être momentanément substitué à un équipement de mesure en panne et permet ainsi d'éviter la dégradation des performances de l'usine.
 - ❖ Réduction des besoins matériels de mesure : Supervision, automate programmable, base de données, les systèmes informatisés sont souvent présents dans la chaîne de production. Ces systèmes peuvent héberger les capteurs logiciels. Les experts peuvent donc être encouragés à concevoir des modèles d'inférence qui sont destinés à remplacer définitivement les capteurs physiques.
 - ❖ Validation du capteur, détection et diagnostic de défauts : Les stratégies de détection et de diagnostic exploitent toujours une certaine forme de redondance. C'est la capacité d'avoir deux ou plusieurs façons de déterminer quelques propriétés caractéristiques (variables, paramètres, symptômes) du processus.

L'idée principale, à partir de laquelle découlent toutes les stratégies de détection de défaut, est de comparer les informations recueillies à l'information correspondante d'une source redondante.

- ❖ Analyse d'hypothèses Le modèle, qui a permis d'élaborer le capteur logiciel, est utilisé dans ce cas pour effectuer une simulation de la dynamique du système correspondant aux tendances d'entrée, dans le but d'obtenir une meilleure compréhension du comportement système. Cette utilisation particulière des modèles de processus pour effectuer une simulation est appelée analyse de scénarios.

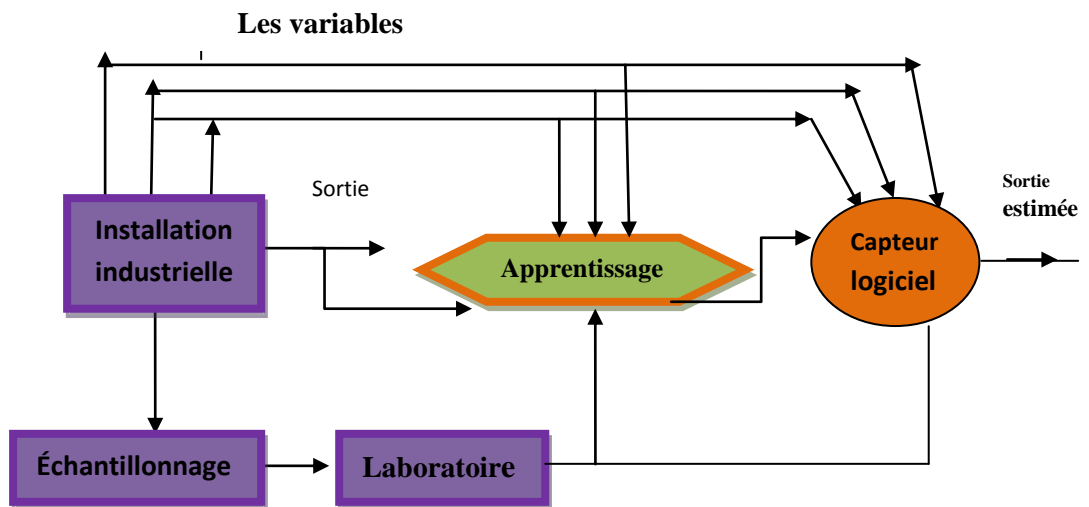


Fig. I.3. Capteur logiciel connecté à l'usine.

Conclusion

Dans ce chapitre nous avons abordées à d'introduction au domaine du contrôle et de surveillance des procédés de production des eaux potables. Les différents procédés d'une chaîne de production d'eau potable sont alors présentés. Définitions des principaux paramètres descripteurs de l'eau ainsi que de leurs capteurs physico-chimiques correspondants. L'accent est mis particulièrement sur une catégorie de capteurs appelée « capteurs logiciels ». Présentés comme étant une solution pouvant être profitable aux systèmes de surveillance, ces capteurs, de conception algorithmique basée sur les techniques de l'intelligence artificielle, présentent des avantages de moindre coût et de simplicité de mise en œuvre.

Le chapitre suivant fera l'objet d'une mise en œuvre théorique des techniques de l'intelligence artificielle basées sur l'apprentissage statistique et appliquées sur des données multi sensorielles. L'objectif, rappelons-le encore une fois, est l'application de ces techniques comme étant une solution dans la conception de capteurs logiciels et de surveillance de la qualité de l'eau par reconnaissance de formes.

Introduction

L'évolution technologique durant les dernières années a permis aux scientifiques d'élaborer et de perfectionner des méthodes pour différents domaines. L'évolution des ordinateurs en particulier et la capacité d'intégration de composants formidable atteintes à nos jours ont permis une grande vitesse de calcul et une grande capacité mémoire. Parmi ces méthodes, il existe deux méthodes qui sont utilisées dans plusieurs domaines de recherches et de différentes manières, ainsi ils peuvent être utilisés d'une manière complètement soft en utilisant uniquement l'ordinateur ou d'une manière hard en utilisant les circuits intégrés. Ces méthodes sont celle des réseaux de neurones artificiels (RNA) et Deep Learning.

Dans le cadre de notre travail, la solution adoptée rappelons-le une fois de plus, est une surveillance et un contrôle de la qualité de l'eau par les technique de reconnaissance de formes. Dans ce chapitre, nous allons donc pouvoir passer en revue des méthodes d'apprentissage statistique appliquées à la classification et la régression.

Après une brève introduction, où nous allons la notion de modèle biologique et neurone formel, nous décrivons définition réseaux de neurones artificiels, modélisation générale, son architecture des réseaux, Les types d'apprentissage des réseaux de neurones et rappelons Les réseaux de neurones les plus utilisés (Perceptron Multi Couches (PMC) et Radial basic fonction (RBF)), ainsi la méthode Deep learning, et les types de ce modèle.

1. Les réseaux de neurones artificiels (RNA)

Les RNA sont des modèles d'entrées-sortie basés sur un caractère des neurones biologiques, le but initial de cette modélisation est de reproduire les capacités du cerveau humain à interpoler ou à classifier.

Selon (Haykin, 1994), un RNA est un processus distribué de manière massivement parallèle, qui a une propension naturelle à mémoriser des connaissances de façon expérimentale et de les rendre disponibles pour utilisation. Il ressemble au cerveau en deux points [21] :

- La connaissance est acquise à travers un processus d'apprentissage
- Les poids des connections entre les neurones sont utilisés pour mémoriser la connaissance.

1.1. Historique

Les recherches menées dans le domaine du connexionnisme ont démarré avec la présentation en 1943 par MCCulloch et Pitts d'un modèle simplifié de neurone biologique communément appelé neurone formel. Ils montrèrent également théoriquement que des

réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes.

En 1949, Hebb propose une théorie fondamentale pour l'apprentissage alors que la proposition du réseau de neurones dit perceptron par Frank Rosenblatt (1958) permettait des applications concrètes. Pratiquement au même moment, Widrow et Off (1960) proposaient un nouvel algorithme d'apprentissage pour entraîner un réseau adaptatif de neurones linéaires, avec des capacités similaires au perceptron. Mais l'enthousiasme suscité par ces théories se trouve fortement contrarié par un livre publié par Minsky et Papert (1969). Les deux auteurs démontraient ainsi les limitations des réseaux développés par Rosenblatt et par Widrow et Off. L'identification de ces limitations en partie dues à la capacité de calcul faible des machines de l'époque, et surtout mal interprétées, a entraîné le ralentissement de la recherche dans le domaine. Malgré cela, Kohonen (1972) et Anderson (Anderson, 1972) publiaient indépendamment de nouvelles architectures semblables. Les cartes auto-organisatrices publiées par Kohonen (1990) constituent une suite de celles de 1972. Dans la décennie 1970, Grossberg (1976) proposait également d'autres réseaux auto-organisés. Dans les années 1980, l'apparition de l'algorithme rétro-propagation relançait fortement l'activité sur les réseaux de neurones. La mise au point de cet algorithme est généralement attribuée à Rumelhart (1986) qui l'a rendu populaire, mais il a été étudié au même moment par Parker (1985) et LeCun (1985) alors que Werbos le décrivait déjà dans sa thèse en 1974.

En hydrologie, connaissant la non-linéarité de la relation pluie-débit, certains auteurs ont exploité les réseaux de neurones artificiels dans la modélisation pluie-débit à différentes échelles (French et al, 1992 ; Shamseldin, 1997).

En effet, depuis 1997, plusieurs centaines d'articles ont été publiés sur l'application des réseaux de neurones à la gestion des ressources en eau. La moitié des applications en hydrologie de ces modèles concernent la relation pluie-débit avec les travaux des auteurs [Dimopououlos et al, 1996 ; Abrahart et See, 2000 ; Schumann et al, 2000 ; Dechemi et al, 2003 ; Li-chiu et al, 2004 ; Wenri et al, (2004) ; Ashu et al, (2004), Benkaci, 2006 et Koffi, 2007].

De nos jours, l'utilisation des réseaux de neurones en hydrologie ne cesse de croître. Les applications en sont multiples et variées [22].

2. Le neurone biologique

Un neurone est une cellule capable de transmettre des informations à d'autres neurones au travers de ses différentes connexions (synapses). Il existe plusieurs types de neurones (pyramide, panier, Purkinje, etc.) avec des fonctionnements différents (sensoriel, moteur,

inter-neurones, etc.). Les neurones sont interconnectés et forment des réseaux [23]. Les neurones reçoivent des signaux (impulsions électriques) par les dendrites et envoient l'information par les axones. Les contacts entre deux neurones (entre axone et dendrite) se font par l'intermédiaire des synapses. Les signaux n'opèrent pas de manière linéaire : effet de seuil [24].




Fig.II.1. Neurone biologique.

2. Généralités sur les réseaux de neurones

2.1 Le neurone formel (artificiel)

Définition : un neurone formel (artificiel) est une unité de traitement qui reçoit des données en entrée, sous la forme d'un vecteur, et produit une sortie réelle. Cette sortie est une fonction des entrées et des poids des connexions [25].

D'une manière très réductrice, un neurone biologique est une cellule qui se caractérise par :

- Des synapses, les points de connexions avec les autres neurones, fibres nerveuses.
- Les dendrites, les entrées du neurone.
- L'axone, 'la sortie' du neurone vers d'autres neurones ou fibres musculaires.
- Le noyau qui active la sortie en fonction du stimulus en entrée.




Fig.II.2. Neurone formel et neurone biologique.

Par analogie, le neurone formel (voir figure 2.4) est une fonction non linéaire, paramétrée, à valeurs bornées, il se caractérise par un état interne ($s \in S$), des signaux d'entrée x_1, x_2, \dots, x_N et une fonction de transition d'état f comme suit

$$s = h(x_1, \dots, x_N) = f(w_0 + \sum_{j=1}^N x_j w_j) \tag{II.1}$$

Un modèle et non copie du neurone biologique = un processeur élémentaire caractérisé par :

- Signaux d'entrées x_0, x_0, \dots, x_n
- Pois des connexions $w_{i0}, w_{i1}, \dots, w_{in}$
- Fonction d'activation $f(x, w)$
- Etat interne d'activation $a = f(x, w)$
- Fonction de transition $f(a)$
- Etat de sortie $s = f(a)$

La fonction de transition est une transformation d'une combinaison des signaux d'entrée. Cette combinaison est déterminée par un vecteur de poids ((w_1, \dots, w_N)) associé à chaque neurone et dont les valeurs sont estimées dans la phase d'apprentissage, θ_0 étant appelé le biais du neurone, il constitue la mémoire ou la connaissance répartie du réseau [26].

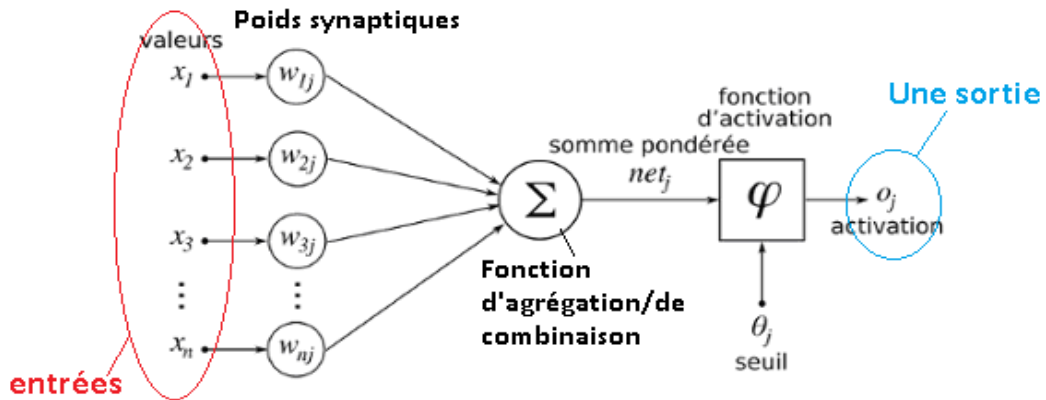


Fig.II.3. Neurone formel.

On résume cette modélisation par le tableau 2.1, qui nous permettra de voir clairement la transition entre le neurone biologique et le neurone formel :

Neurone biologique	Neurone artificiel
Synapses	Poids de connexions
Axones	Signal de sortie
Dendrite	Signal d'entrée
Somma	Fonction d'activation

Tab.II.1. La transition entre le neurone biologique et le neurone formel.

2.3. Principe du neurone artificiel

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont ou des capteurs composant la machine dont il fait partie. A chacune de ses entrées est associé un poids représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval. A chaque connexion est associé un poids.

Le neurone réalise alors trois opérations sur ses entrées [27] :

- Pondération : multiplication de chaque entrée par un paramètre appelé poids de connexion,
- Sommation : une sommation des entrées pondérées est effectuée
- Activation : passage de cette somme dans une fonction, appelée fonction d'activation.

3. Caractérisation d'un RNA

- Une architecture (topologie).
- Une méthode d'apprentissage.
- Une/des fonction(s) d'activation, ou fonction(s) de sortie, pour les neurones le composant.

3.1. Architecture des réseaux de neurones

On distingue deux structures de réseau, en fonction du graphe de leurs connexions, c'est-à-dire du graphe dont les nœuds sont les neurones et les arêtes les «connexions» entre ceux-ci [27]:

- Les réseaux de neurones statiques (ou acycliques, ou non bouclés).
- Les réseaux de neurones dynamiques (ou récurrents, ou bouclés).

3.1.1. Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées par chacun de ses neurones. Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones "connectés" entre eux, l'information circulant des entrées vers les sorties sans "retour en arrière"; si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les "connexions" entre ceux-ci, le graphe d'un réseau non bouclé est acyclique. Le terme de "connexions" est une métaphore : dans la très grande majorité des applications, les réseaux de neurones sont des formules algébriques dont les valeurs numériques sont calculées par des programmes d'ordinateurs, non des objets physiques (circuits électroniques spécialisés) ;

néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage, car il est commode quoique trompeur. Il a même donné naissance au terme de connexionnisme.

3.1.1.1. Réseaux de neurones monocouches

La structure d'un réseau monocouche est telle que des neurones organisés en entrée soient entièrement connectés à d'autres neurones organisés en sortie par une couche modifiable de poids (figure II.4).




Fig.II.4. Schéma d'un réseau de neurones monocouche.

3.1.1.2. Réseaux de neurones multicouches

Les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche, et les connexions ne se font qu'avec les neurones de couches avales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.

La figure (II.5) représente un réseau de neurones non bouclé qui a une structure particulière, très fréquemment utilisée : il comprend des entrées, deux couches de neurones cachés et des neurones de sortie. Les neurones de la couche cachée ne sont pas connectés entre eux. Cette structure est appelée Perceptron multicouches [28].

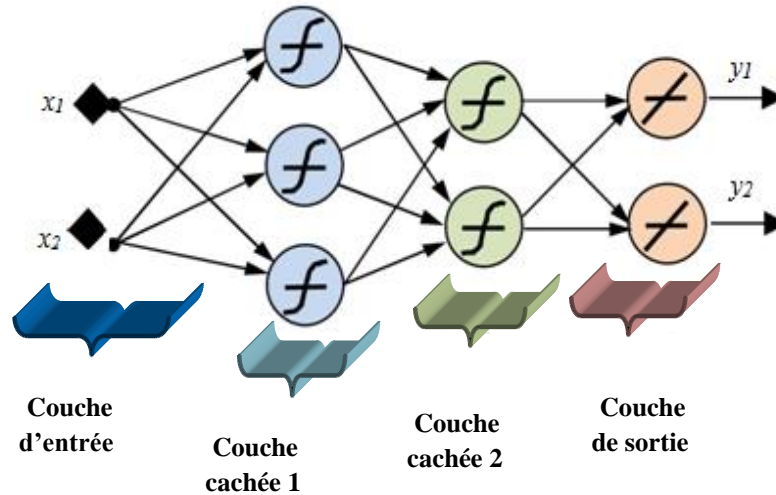


Fig.II.5. Schéma d'un réseau de neurones non bouclé (Perceptron multicouches).

3.1.2. Réseaux de neurones à connexions locales

Il s'agit d'une structure multicouche, mais qui à l'image de la rétine conserve une certaine topologie. Chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche avale. Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique (figure 2.6).




Fig.II.6. Schéma d'un réseau de neurones à connexions locales.

3.1.3. Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés dont le graphe de connexions est acyclique, les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties. Pour qu'un tel système soit causal, il faut évidemment qu'à toute boucle soit associé un retard : un réseau de neurones bouclé est donc un système dynamique, régi par des équations différentielles ; comme l'immense majorité des applications sont réalisées par des programmes d'ordinateurs, on se place dans le cadre des systèmes à temps discret, où les équations différentielles sont remplacées par des équations aux différences.

Il s'agit donc de réseaux de neurones avec retour en arrière (feedback network or recurrent network), (Figure II.7).




Fig.II.7. Schéma de réseau de neurones bouclé

Les réseaux de neurones bouclés sont utilisés pour effectuer des tâches de modélisation de systèmes dynamiques, de commande de processus, ou de filtrage [28].

3.2. L'apprentissage des réseaux de neurones

Le point crucial du développement d'un réseau de neurones est son apprentissage. Il s'agit d'une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information (Hebb, 1949; Grossberg, 1982; Rumelhart et al, 1986). Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent : il existe des algorithmes d'optimisation non linéaire extrêmement rapides (Press et al, 1992).

Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage.

Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. Il existe plusieurs règles d'apprentissage qui peuvent être

regroupées en trois catégories (Benkaci, 2006): apprentissage supervisé, apprentissage non supervisé, apprentissage.

3.2.1. Apprentissage supervisé

Apprentissage supervisé doit disposer d'un comportement de référence précis pour pouvoir l'inculquer au réseau neural [29], L'apprentissage "supervisé" pour les réseaux de neurones formels, consiste à calculer les coefficients synaptiques de telle manière que les sorties du réseau soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties "désirées". Ils peuvent être la classe d'appartenance de [30] :

- La forme que l'on veut classer
- La valeur de la fonction que l'on veut approcher
- La sortie du processus que l'on veut modéliser
- La sortie souhaitée du processus à commander.

L'apprentissage supervise est illustre d'une manière conceptuelle a la figure II.8 L'environnement est inconnu du réseau. Celui-ci produit un stimulus p qui est acheminé à la fois au professeur et au réseau. Grace à ses connaissances intrinsèques, l'expert produit une sortie désirée $d(t)$ pour ce stimulus. On suppose que cette réponse est optimale. Elle est ensuite comparée (par soustraction) avec la sortie du réseau pour produire un signal d'erreur $e(t)$ qui est réinjecté dans le réseau pour modifier son comportement via une procédure itérative qui, éventuellement, lui permet de simuler la réponse d'expert. Autrement dit, la connaissance de l'environnement par l'expert est graduellement transférée vers le réseau jusqu'à l'atteinte d'un certain critère d'arrêt. Par la suite, on peut éliminer l'expert et laisser le réseau fonctionner de façon autonome. [31].

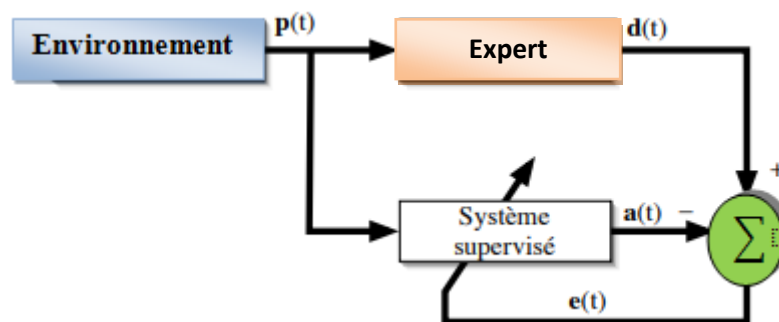


Fig.II.8. Schéma bloc de l'apprentissage supervise.

3.2.2. Apprentissage non-supervisé

L'apprentissage auto organisation utilise les entrées de système seulement, sans le comportement de Référence [32]. Elle est caractérisée par l'absence complète d'expert, c'est-à-dire qu'on ne dispose ni d'un signal d'erreur, comme dans le cas supervisé, ni d'un indice de satisfaction, comme dans le cas par renforcement. Nous ne disposons donc que d'un environnement qui fournit des stimuli, et d'un réseau qui doit apprendre sans intervention externe. En assimilant les stimuli de l'environnement à une description de son état interne, la tâche du réseau est alors de modéliser cet état le mieux possible. Pour y arriver, il importe d'abord de définir une mesure de la qualité pour ce modèle, et de s'en servir par la suite pour optimiser les paramètres libres du réseau, c'est-à-dire ses poids synaptiques. À la fin de l'apprentissage, le réseau a développé une habilité à former des représentations internes des stimuli de l'environnement permettant d'encoder les caractéristiques de ceux-ci et, par conséquent, de créer automatiquement des classes de stimuli similaires [28].

Ce type d'apprentissage construit une représentation interne de la connaissance issue de l'environnement [31].



Fig.II.9. Schéma bloc de l'apprentissage supervisé.

3.2.3. Apprentissage par renforcement

L'apprentissage par renforcement permet de contourner certaines des limitations de l'apprentissage supervisé. Il consiste en une espèce d'apprentissage supervisé, mais avec un indice de satisfaction scalaire au lieu d'un signal d'erreur vectoriel [28], qui ne nécessite pas de comportement de référence explicite mais seulement d'information comme un encouragement ou une pénalisation [31].




Fig.II.10. Schéma bloc de l'apprentissage supervisé.



Les algorithmes d'apprentissages donnent de meilleurs résultats lorsqu'on leur fournit des exemples multiples et variés ; ainsi le réseau peut assimiler toutes les connaissances. Ils existent différents règles d'apprentissages parmi lesquelles on peut distinguer :

- La règle de Widrow-Hoff,
- La règle de Perceptron,
- La règle de Grossbergen, ect

3.3. Les fonctions d'activation

Il se trouve que plusieurs possibilités existent. Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone sont énumérées au tableau II.2. Les fonctions d'activations les plus utilisées sont les fonctions «seuil» (en anglais «hard limit»), «linéaire» et «sigmoïde».

Nom de la fonction	Relation entrée/sortie	Icône	Nom MATAB
Seuil	$y = 0$ si $s < 0$ $y = 1$ si $s \geq 0$		hardlim
Seuil symétrique	$y = -1$ si $s < 0$ $y = 1$ si $s \geq 0$		hadlims
Linéaire	$y = s$		purelin
Linéaire saturée	$y = 0$ si $s \leq 0$ $y = s$ si $0 \leq s \leq 1$ $y = 1$ si $s \geq 1$		satlin
Linéaire saturée symétrique	$y = -1$ si $s < -1$ $y = s$ si $-1 \leq s \leq 1$ $y = 1$ si $s > 1$		satlins
Linéaire positive	$y = 0$ si $s \leq 0$ $y = s$ si $s \geq 0$		poslin
Sigmoïde	$y = \frac{1}{1 + \exp^{-s}}$		logsig

Tangente hyperbolique	$y = \frac{e^s - e^{-s}}{e^s + e^{-s}}$		tansig
Compétitive	$y = 1$ si s maximum $y = 0$ autrement		compet

Tab.II.2. Différentes fonctions d'activations utilisées dans les RNA.

4. Réseau de neurones de type MLP (Multi Layer Perceptron - MLP)

4.1. Perceptrons Multicouches

Les réseaux de neurones de type Perceptrons Multicouches (Multi Layer Perceptron - MLP) sont des réseaux à propagation avant, composés d'une ou plusieurs couches cachées et d'une couche de sortie. Chaque couche du réseau est composée de neurones artificiels. La première couche cachée reçoit l'information provenant des entrées. L'information est traitée et transmise vers les couches suivantes jusqu'à la dernière. Les MLP sont connus comme étant des approximateurs universels et sont très utilisés dans des problèmes de régression non linéaire [33]. Les signaux se propagent de l'entrée vers la sortie (direction de propagation avant). La fonction de transfert est de type sigmoïdale (log-sigmoïde). Pour effectuer l'apprentissage nous avons utilisé une modification de l'algorithme standard de rétro-propagation appelé la "rétro-propagation avec terme de moment". Le moment permet au réseau de répondre non seulement au gradient local mais aussi aux tendances récentes de la surface d'erreur (hyper-surface de la fonction de coût vis-à-vis des paramètres libres du réseau, c'est-à-dire les poids synaptiques) [34].

4.2. Processus d'apprentissage dans les réseaux MLP

Les réseaux MLP utilisent un mode d'apprentissage supervisé. Dans ce mode d'apprentissage, un ensemble de données constitue des entrées du système à modéliser et des sorties correspondantes est présente au réseau qui doit adapter ses paramètres suivant un algorithme d'apprentissage de façon à ce que la divergence entre la sortie du système et celle du modèle soit suffisamment faible .

4.2.1. L'algorithme de rétropropagation

Les techniques d'apprentissage les plus utilisées dans les réseaux MLP sont l'algorithme de rétropropagation du gradient.

L'algorithme de rétropropagation du gradient (RP) est certainement à la base des premiers succès des réseaux de neurones. Sa mise en application a permis au domaine du connexionnisme de sortir de la période de silence qui a régné après la sortie du livre « Perceptrons » de Minsky et Papert.

On considère un réseau à trois couches illustré par la figure II.11. Les conventions de notation sont les suivantes :

o_k activation de la k^e unité de sortie, $k = 1, \dots, n, M$;

t_k activation désirée de la k^e unité de sortie;

c_j activation de la j^e unité cachée, $j = 0, 1, \dots, n_h$; $c_0 = 1$: c'est l'entrée du biais pour la couche de sortie;




Figure II.11. Exemple d'algorithme de rétropropagation.

x_i , i^e entrée externe du réseau; $i = 0, 1, \dots, n, n$; $x_0 = 1$: entrée du biais pour la couche cachée, w_{ji} poids d'une connexion entre la i^e entrée et la j^e unité cachée, (x_i , i^e v_{kj} poids d'une connexion entre la j^e unité cachée et la k^e unité de sortie.

Les indices i , j et k font référence aux unités d'entrée, aux unités cachées et aux unités de sortie, respectivement. L'exposant p correspond au numéro de l'exemple présenté à l'entrée du réseau : $p = 1, \dots, n_A$, où n_A est le nombre d'exemples d'apprentissage. Le p^e exemple est noté $x^p = [x_0^p, \dots, x_1^p, \dots, x_n^p]$ et la i^e composante x_i^p désigne la i^e entrée lorsque le p^e exemple est présenté au réseau. Les valeurs x_i^p peuvent être binaires ou continues. Pour un exemple p , la j^e unité cachée a l'entrée résultante I_j^p :

$$I_j^p = \sum_{i=0}^n w_{ji} x_i^p \quad (\text{II.2})$$

et une activation

$$c_j^p = h(I_j^p) = h\left(\sum_{i=0}^n w_{ji} x_i^p\right) \quad (\text{II.3})$$

où h est la fonction d'activation. La k^e unité de sortie reçoit une entrée résultante I_k^p définie

$$\text{par : } I_k^p = \sum_{j=0}^n v_{kj} c_j^p \quad (\text{II.4})$$

et génère en sortie l'activation o_k^p

$$o_k^p = h(I_k^p) \quad (\text{II.5})$$

Pour l'application du MLP en régression, la fonction d'activation des neurones de sorties est linéaire. L'équation (2.5) devient :

$$o_k^p = I_k^p \quad (\text{II.6})$$

On prend une fonction d'activation non-linéaire h uniquement dans le cas de l'application

en discrimination. Dans le cadre de cette mémoire, nous nous intéresserons uniquement à l'application de MLP en régression.

La fonction de coût usuelle est l'erreur quadratique moyenne définie comme :

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k,p} (t_k^p - o_k^p)^2 \quad (\text{II.7})$$

où \mathbf{w} est le vecteur contenant tous les poids du réseau. La fonction $E(\mathbf{w})$ est continue et différentiable par rapport à chaque poids. Pour déterminer les poids qui la minimisent, on peut donc utiliser l'algorithme de descente du gradient. Pour faciliter la notation, $E(\mathbf{w})$ sera notée E dans ce qui suit.

Pour les poids des connexions des unités cachées vers les unités de sortie, le terme d'adaptation des poids au cours de l'apprentissage est défini par :

$$\begin{aligned} \Delta v_{kj} &= -\eta \frac{\partial E}{\partial v_{kj}} \\ &= \eta \sum_p \delta_k^p c_j^p \end{aligned} \quad (\text{II.8})$$

avec

$$\delta_k^p = (t_k^p - o_k^p)$$

dans le cas de sorties linéaires.

Pour les poids des connexions entre la couche d'entrée et la couche cachée, le terme d'adaptation des poids est :

$$\begin{aligned} \Delta w_{ji} &= -\eta \frac{\partial E}{\partial w_{ji}} \quad (\text{II.9}) \\ &= -\eta \frac{\partial E}{\partial c_j^p} \frac{\partial c_j^p}{\partial w_{ji}} \\ &= \eta \sum_{k,p} (t_k^p - o_k^p) v_{kj} h'(I_j^p) x_i^p \\ &= \eta \sum_p \delta_j^p x_i^p \end{aligned}$$

Avec

$$\delta_j^p = h'(I_j^p) \sum_k v_{kj} \delta_k^p \quad (\text{II.10})$$

On peut constater que les équations (II.10) et (II.9) ont la même forme et ne diffèrent que par la définition de la quantité δ . Ces formules se généralisent facilement aux cas des réseaux possédant un nombre quelconque de couches cachées. D'après l'équation (II.10), le calcul de δ_j pour une unité cachée j nécessite les δ_k des unités de sortie, qui sont fonctions des erreurs en sortie du réseau ($t_k - o_k$). Ainsi, pour corriger les poids des connexions entre la couche d'entrée et la couche cachée, on a besoin de rétro-propager l'erreur depuis les sorties vers les entrées, d'où le nom de l'algorithme d'apprentissage : rétro-propagation de l'erreur [16].

5. Réseau de neurones de type RBF (Radial Basis Functions)

5.1. Définition d'un réseau RBF

Introduit par Powell et Broomhead, le réseau RBF (Radial Basis Functions) fait partie des réseaux de neurones supervisés. Il est constitué de trois couches comme représenté dans la figure 2.: une couche d'entrée qui retransmet les entrées sans distorsion, une seule couche cachée qui contient les neurones RBF qui sont généralement des gaussiennes et une couche de sortie dont les neurones sont généralement animés par une fonction d'activation linéaire. Chaque couche est complètement connectée à la suivante et il n'y a pas de connexions à l'intérieur d'une même couche [35], [36], [37].

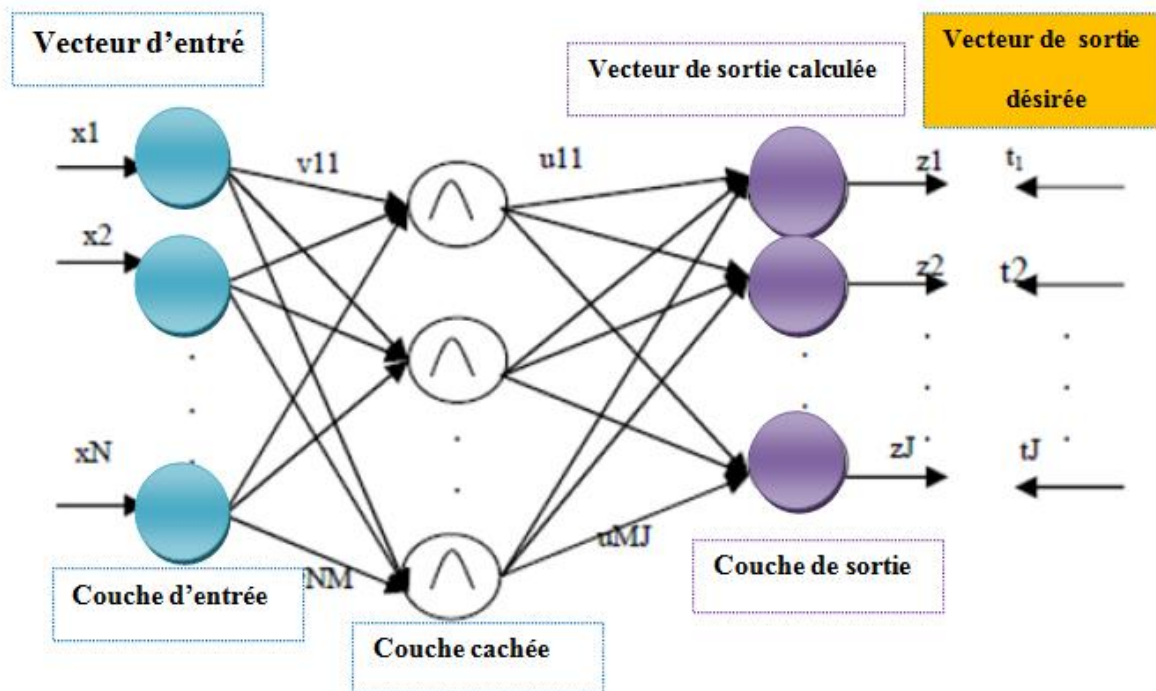


Figure II.12. Structure d'un réseaux RBF.

Ce réseau est constitué de N neurones d'entrée, M neurones cachés et J neurones de sortie. La sortie du $m^{\text{ième}}$ neurone de la couche cachée est donnée par :

$$y_m^{(q)} = \exp \left[-\frac{\|x^{(q)} - v_m\|^2}{2\delta_m^2} \right] \quad (\text{II.11})$$

v_m est le centre du $m^{\text{ième}}$ neurone de la couche cachée où du $m^{\text{ième}}$ neurone gaussien et σ_m est la largeur du $m^{\text{ième}}$ gaussienne.

La sortie du $j^{\text{ième}}$ neurone de la couche de sortie est donnée par:

$$z_j^{(q)} = \left(\frac{1}{M}\right) \cdot \left[\sum_{m=1, M} w_{mj} Y_m^{(q)}\right] \quad (\text{II.12})$$

$m=1, \dots, M$ et $j=1, \dots, J$.

w_{mj} sont les poids reliant la couche cachée à celle de la sortie.

5.2. Algorithme d'apprentissage du réseau RBF

L'apprentissage du réseau RBF a été présenté la première fois par Moody et Darken. Il consiste à régler quatre paramètres principaux: le nombre de neurones dans l'unique couche cachée ou le nombre des gaussiennes, la position des centres de ces gaussiennes, la largeur de ces gaussiennes et les poids de connexions entre les neurones cachés et le(s) neurone(s) de sortie. Le réseau RBF consiste à minimiser l'erreur quadratique totale E calculée entre les sorties obtenues du réseau et celles désirées [38] :

$$E = \sum_{q=0}^Q \sum_{j=1}^J t_j^{(q)} z_j^{(q)2} \quad (\text{II.13})$$

Pour le réseau RBF, l'ajustement des poids w_{mj} reliant la couche cachée à celle de la sortie est réalisé par la règle de Widrow-Hoff. Il se fait comme suit :

$$w_{mj}^{(i+1)} = w_{mj}^{(i)} + \eta(t_j - z_j) y_m \quad (\text{II.14})$$

est la sortie du $j^{\text{ième}}$ neurone désirée, z_j est la sortie du $j^{\text{ième}}$ neurone calculée, y_m est la sortie du $m^{\text{ième}}$ neurone de la couche cachée et η est le pas d'apprentissage dont sa valeur est comprise entre 0 et 1 [3].

La modélisation des réseaux RBF est généralement composée de deux étapes distinctes : la paramétrisation des fonctions-noyaux et l'apprentissage des poids de la couche de sortie. Cette dernière étape ne concerne qu'une seule couche de connexions et peut être réalisée par des techniques d'apprentissage simples telles que la règle Delta ou de Widrow-Hoff. Avec une seule couche cachée, les réseaux RBF se comportent comme des approximateurs universels. Les réseaux RBF obtiennent des performances comparables ou supérieures à celles des réseaux MLP dans l'approximation de fonctions. Une particularité intéressante est la rapidité et la simplicité dans l'apprentissage faisant de ces réseaux des outils de choix pour des systèmes de classification de signaux. D'un point de vue pratique, les réseaux RBF sont moins sensibles aux pertes de mémoire résultant de la destruction de leurs poids. Dans la configuration de base, ce type de réseau est constitué de deux couches dont une agit comme la couche cachée. La première couche qui n'est pas comptabilisée est la couche d'entrée dont les fonctions d'activation sont linéaires, telle que la fonction « purelin ». La couche cachée est

constituée de fonctions de type gaussien telle que la fonction « radbas » fournie par MATLAB. Finalement, la couche de sortie comporte des fonctions d'activation non-linéaires telles que la fonction « tansig » [39].

6. Deep Learning

Le Deep Learning est un nouveau domaine de recherche du Machine Learning (ML), qui a été introduit dans le but de rapprocher le ML de son objectif principal : l'intelligence artificielle. Il concerne les algorithmes inspirés par la structure et le fonctionnement du cerveau. Ils peuvent apprendre plusieurs niveaux de représentation dans le but de modéliser des relations complexes entre les données.




Fig.II.13. La relation entre l'intelligence artificielle, le machine learning (ML) et le Deep Learning [40].

Le Deep Learning est basé sur l'idée des réseaux de neurones artificiels et il est taillé pour gérer de larges quantités de données en ajoutant des couches au réseau. Un modèle de Deep Learning a la capacité d'extraire des caractéristiques à partir des données brutes grâce aux multiples couches de traitement composé de multiples transformations linéaires et non linéaires et apprendre sur ces caractéristiques petit à petit à travers chaque couche avec une intervention humaine minimale. Sur les cinq dernières années, le Deep Learning est passé d'un marché de niche ou seulement une poignée de chercheurs s'y intéressait au domaine le plus prisé par les chercheurs.

6.1. Historique du deep learning

Année	Contributeur	Contribution
2006	Geoffrey Hinton	introduction des Deep belief Network
2009	Salakhutdinov and Hinton	introduction des Deep Boltzmann Machines

2012	Alex Krizhevsky	introduction d'AlexNet qui remporta le challenge ImageNet
------	-----------------	--

Tab.II.3. L'historique du Deep Learning.

Une des grandes différences entre le Deep Learning et les algorithmes de ML traditionnelles c'est qu'il s'adapte bien, plus la quantité de données fournie est grande plus les performances d'un algorithme de Deep Learning sont meilleurs. Contrairement à plusieurs algorithmes de ML classiques qui possèdent une borne supérieure à la quantité de données qu'ils peuvent recevoir des fois appelée "plateau de performance", les modèles de Deep Learning n'ont pas de telles limitations (théoriquement) et ils sont même allés jusqu'à dépasser la performance humaine dans des domaines comme l'image processing.

BIG DATA & DEEP LEARNING




Fig.II.14. La différence de performance entre le Deep Learning et la plupart des algorithmes de ML en fonction de la quantité de données

Autre différence entre les algorithmes de ML traditionnelles et les algorithmes de Deep Learning c'est l'étape de l'extraction de caractéristiques. Dans les algorithmes de ML traditionnelles l'extraction de caractéristiques est faite manuellement, c'est une étape difficile et coûteuse en temps et requiert un spécialiste en la matière alors qu'en Deep Learning cette étape est exécutée automatiquement par l'algorithme.

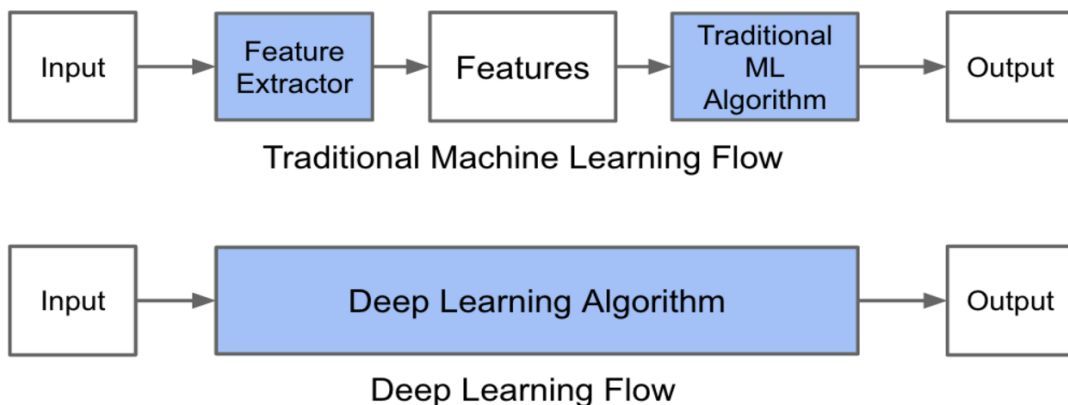


Fig.II.15. Le procédé du ML classique comparé à celui du Deep Learning.

6.2. Les différents types de modèles

Il existe un grand nombre de variantes d'architectures profondes. La plupart d'entre elles sont dérivées de certaines architectures parentales originales. Il n'est pas toujours possible de comparer les performances de toutes les architectures, car elles ne sont pas toutes évaluées sur les mêmes ensembles de données. Le Deep Learning est un domaine à croissance rapide, et de nouvelles architectures, variantes ou algorithmes apparaissent toutes les semaines [40].

6.2.1. Les réseaux de neurones convolutifs

Convolutional Neural Network (CNN) (réseaux de neurones convolutifs) sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Les exemples comprennent des données de type série temporelle, qui peuvent être considérées comme une grille 1D en prenant des échantillons à des intervalles de temps réguliers et des données de type image, qui peuvent être considérées comme une grille 2D de pixels. Les réseaux convolutés ont connu un succès considérable dans les applications pratiques. Le nom « réseau de neurones convolutés » indique que le réseau emploie une opération mathématique appelée convolution. La convolution est une opération linéaire spéciale. Les réseaux convolutés sont simplement des réseaux de neurones qui utilisent la convolution à la place de la multiplication matricielle dans au moins une de leurs couches.




Fig.II.16. Exemple image 1000x1000. (à gauche) Le non parameter sharing nous oblige à concevoir une couche cachée de 10^6 neurones, chaque neurone est connecté à 106 pixels, en tout ça fait 10^{12} paramètres. (à droite) Avec un noyau 10x10 et une couche cachée 10^6 de neurones, le nombre de paramètres est de 10^8 .

6.2.2. Réseau de neurones récurrents

RNN (les réseaux de neurones récurrents) sont appelés récurrents car ils exécutent la même tâche pour chaque élément d'une séquence, la sortie étant dépendante des calculs précédents.

Une autre façon de penser les RNN est qu'ils ont une « mémoire » qui capture l'information sur ce qui a été calculé jusqu'ici. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais dans la pratique, on les limite à regarder seulement quelques étapes en arrière.

6.2.3. Deep générative model

Alors qu'un modèle discriminatif (ex : CNN, RNN, MLP) essaye de prédire $p(y,x)$ avec y étant le label et x l'entrée, un modèle génératif décrit comment les données sont générées, il apprend $p(x|y)$ et fait des prédictions en utilisant la loi de Bayes pour calculer $p(y,x)$. Si le but est juste la classification, alors il faut utiliser un modèle discriminatif, cependant les modèles génératifs sont capables de bien plus que la simple classification comme par exemple générer de nouvelles observations [40].

Voici quelques exemples de modèle génératif :

- Adversarial autoencoders.
- Generative Adversarial Networks.
- Generative Stochastic Networks

6.3. Auto encodeur

Définition

Auto encodeur est un réseau de neurones artificiels utilisé pour l'apprentissage non supervisé. L'objectif d'un auto-encodeur est d'apprendre une représentation (encodage) d'un ensemble de données, généralement dans le but de réduire la dimension de cet ensemble. Récemment, le concept d'auto-encodeur est devenu plus largement utilisé pour l'apprentissage de modèles génératifs.

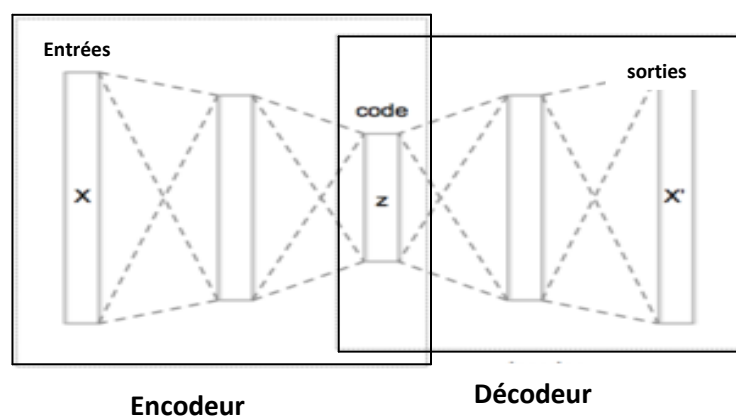


Fig.II.17. Structure schématique d'un auto-encodeur avec 3 couches cachées entièrement connectées.

La forme la plus simple d'un auto-encodeur est un réseau de neurones non récurrents qui se propage vers l'avant, très semblable au perceptron multicouches - ayant une couche d'entrée, une couche de sortie ainsi qu'une ou plusieurs couches cachées les reliant -, mais avec toutefois une couche de sortie possédant le même nombre de nœuds que la couche d'entrée, son objectif étant de reconstruire ses entrées (plutôt que de prédire une valeur cible étant donné les entrées). Par conséquent, un auto-encodeur est un modèle d'apprentissage non supervisé.

6.3.1. Apprentissage

L'algorithme d'apprentissage d'un auto-encodeur peut être résumé comme suit :

Pour chaque entrée x , effectuer un passage vers l'avant afin de calculer les activations sur toutes les couches cachées, puis sur la couche de sortie pour obtenir une sortie mesure l'écart entre et l'entrée généralement en utilisant l'erreur quadratique, rétropropager l'erreur vers l'arrière et effectuer une mise à jour des poids.

Conclusion

Ce chapitre a fait l'objet de rappels des fondements des méthodes et techniques d'apprentissage statistique appliqués à la classification et à la régression. En premier, nous avons rappelé les concepts fondamentaux qui sont à la base des réseaux de neurones artificiels (MLP) et réseaux de neurones à base radiale (RBF), Les réseaux de neurones artificiels, sont le cœur de plusieurs applications réelles, un outil indispensable qui a fait ses preuves dans la pratique par leurs caractéristiques rêver les chercher qui veulent avoir le parfait. Alors ces réseaux-là ne sont en fait qu'un : Utilisant un nombre d'algorithmes d'apprentissage afin de réaliser une tâche généralement la classification, prédiction, approximation. En deuxième partie nous avons vu qu'est ce que le Deep Learning, les différents types, et leur performance.

Introduction

Ce dernier chapitre est consacré à la simulation et vise l'application des techniques étudiées comme étant une solution dans la conception des capteurs logiciels et de surveillance de la qualité de l'eau par reconnaissance de formes. L'objectif est de valider et d'évaluer les performances de chacune des méthodes présentées. Les exigences principales d'efficacité sont formulées sur deux points essentiels à savoir, les tests de spécification qui vérifient que le programme réalise bien la tâche pour laquelle il a été conçu, et les tests de performances qui vont servir à mesurer l'efficacité avec laquelle cette tâche est remplie. Afin de mener une étude comparative permettant un choix décisif de la méthode la mieux adaptée à l'application indiquée, on évaluera pour les méthodes exposées les paramètres liés au taux de reconnaissance et temps d'apprentissage. Le développement d'un capteur logiciel de chlore (CL) vu comme un problème de régression (station européen), et le contrôle de potabilité de l'eau en tant que de classification (station local), Une discussion des résultats conclura cette étude de simulation pour choisir la technique la mieux adaptée.

1. Problématique

1.1 Architecture du système de contrôle et de surveillance

Il s'agit dans cette partie de travail d'évaluer les performances des trois techniques étudiées précédemment qui sont issues, rappelons-le, du domaine de l'intelligence artificielle à savoir, les réseaux neuronal-MLP, les réseaux neuronal-RBF et Deep-Learning. Des techniques servant comme outils de base pour l'aide à la décision et présentant une réponse plus élaborée par rapport aux autres techniques se basant sur des données brutes, venant directement des variables de surveillance, ou à partir de données traitées venant des sorties de traitements de bas niveau. Le choix effectué sur la base des résultats obtenus, conduira à l'intégration de la technique sélectionnée au niveau d'un système de surveillance assurant un contrôle permanent de la qualité de l'eau. L'architecture de ce système imaginé est basée sur une approche multi- sensorielle et présentée dans la figure 3.1. Le processus de contrôle est vu comme un problème de reconnaissance de formes, où les classes correspondent aux différents états de l'eau, et les formes représentent l'ensemble des observations ou mesures des paramètres liés à ses caractéristiques.

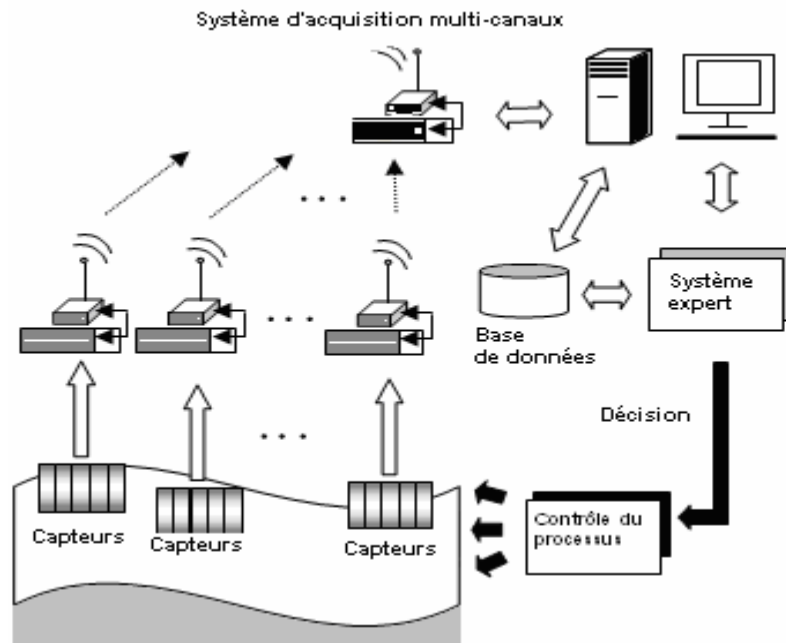


Fig.II.1. Architecture du système de contrôle et de surveillance.

Au niveau du système, on peut supposer que les différents paramètres physico-chimiques utilisées, tels que le pH, la conductivité (C), l'oxygène dissous (OD), matière en suspension (SM), le chlore (CL). Sont transformés en signaux électriques à partir des capteurs, et transmis vers une station de contrôle qui assure l'acquisition, le traitement et l'analyse. La technique de surveillance utilisée effectue après chaque acquisition, la classification et la séparation des données en plusieurs classes bien différentes. Une suite d'acquisitions pourrait être envisagée plusieurs fois par jour, sous des conditions prédéfinies. Un module d'apprentissage supervisé par un expert, permet de collecter de manière continue les paramètres relatifs aux différents états de l'eau pour la mise en œuvre d'une base de connaissance complète.

1. 2 Approche utilisée dans la surveillance

La solution devant être adoptée par les techniques citées ci-dessus au problème de reconnaissance de formes posé, ne s'applique en fait que si on se trouve dans le cas d'un apprentissage supervisé. Nous procédons donc lors d'une étape préliminaire d'apprentissage. L'étape de test ou de reconnaissance proprement dite, s'effectue une fois le modèle statistique établi. Il y a ici tout l'intérêt pour dire que cette approche se caractérise par sa souplesse et sa généralité. A souligner toutefois que les méthodes de reconnaissance de formes à base d'apprentissage statistique sont les plus utilisées dans les systèmes de classification et régression. En général l'apprentissage est une étape assez longue, et nécessite plus de temps de calcul. Les techniques partagent ce point commun mais diffèrent sur un certain nombre d'autres points. L'étude comparative effectuée dans les paragraphes suivants en fera la différence. Ces critères (temps d'apprentissage, temps de test, corrélation,...etc.) aussi

important dans le choix du modèle de reconnaissance, évoque un traitement hors ligne devant être effectué par le système de surveillance. Le déroulement de cette opération en permanence contribue sans doute à enrichir une base de connaissance qu'on veut qu'elle soit la plus complète possible pour le modèle de surveillance implanté.

2. Développement d'un capteur logiciel de Chlore

Dans cette partie de travail on s'intéresse à la conception d'un capteur logiciel (CL) permettant de fournir une information sur le chlore à partir d'autres paramètres physico-chimiques issus de capteurs physiques. L'intérêt aussi bien économique que technique, permet d'assurer un fonctionnement permanent et stable de l'analyse et la surveillance de l'état de l'eau. Le problème posé est vu comme un problème de régression, où la sortie du capteur logiciel correspond à la quantité de chlore estimée.

Le but recherché quant au choix d'une méthode adaptée, se limite à une simulation appliquée sur des données réelles. Une évaluation des performances de cette application en matière de temps d'exécution, coefficient de corrélation et l'erreur d'entraînement. Les différents types des modèles de comportement possibles (neuronal-MLP, neuronal-RBF et Deep Learning) possèdent l'avantage de pouvoir intrinsèquement décrire des relations non linéaires entre les variables d'entrée et celles de sortie d'un processus donné. Il reste alors à identifier les paramètres du modèle, une étape connue sous le terme d'apprentissage. En effet, les données de l'historique sont d'abord séparées en deux groupes : un groupe de données constituant la base d'apprentissage, et un groupe de données de test non utilisées lors de l'apprentissage, mais servant à « tester » le modèle lors de la phase de reconnaissance une fois celui-ci établi. Dans le but de montrer l'intérêt et l'efficacité des méthodes d'apprentissage statistique dans la conception de ce type de capteurs, trois modèles sont évalués et comparés dans ce qui suit à savoir, les réseaux neuronal-MLP, les réseaux neuronal-RBF et Deep Learning.

2.1. Description des données d'entrées

Nous cherchons à décider sur la qualité de l'eau à travers ses paramètres descripteurs. Nous n'avons en fait aucune connaissance a priori sur un type de modèle représentant parfaitement ce procédé, par contre nous pouvons porter notre jugement sur la qualité de cette eau à partir de quelques données descriptives. Il y a quatre paramètres physico-chimiques, qui renseignent sur les dangers majeurs qu'il faut surveiller. Ces paramètres sont résumés comme suit : Conductivité (C), pH, Oxygène dissous (OD) et Matières en suspension (SM). Les données descriptives expérimentales recueillies sur une longue période (plusieurs années) pourraient atteindre cet objectif. A noter que le pH, et l'oxygène dissous sont fortement

dépendants des phénomènes saisonniers. Il y a donc intérêt de disposer d'au moins une année pour archiver des données afin de déterminer une base de connaissance assez complète capable de fonctionner normalement. D'où la nécessité d'une base de connaissance riche en informations exigeant d'abord une collecte des données sur une longue période, et la présence d'un expert.

2.2. Apprentissage et Test

Afin de procéder aux tests, on peut d'emblée supposer qu'en matière de reconnaissance, un taux de plus de 75 % est en général jugé satisfaisant. On présente d'abord un ensemble de données extrait d'une base réelle et constitué de 600 échantillons ou vecteurs, correspondant aux quatre paramètres physico-chimiques (pH, SM, DO, et C) avec un 5^{ème} paramètre qui est le chlore (CL). Nous divisons la base réelle à trois bases (400, 500, 600) comme le tableau III.1

Les bases de données	Nombre d'échantillons	Phase	
		Apprentissage	Test
Base 1	400	300	100
Base 2	500	375	125
Base 3	600	450	150

Tab.III.1. Les bases des données.

L'ensemble des échantillons sont séparés en deux, à savoir, $\frac{3}{4}$ échantillons utilisés pour l'apprentissage, le reste est utilisé pour le test. Notons toutefois que ces paramètres choisis (pH, SM, DO, et C) sont corrélés avec la sortie désirée qui représente le taux de chlore. La corrélation entre les paramètres E/S joue donc un rôle essentiel dans la conception de capteurs logiciels. La figure III.2 montre l'évolution de ces quatre paramètres descripteurs utilisés dans la phase d'apprentissage.

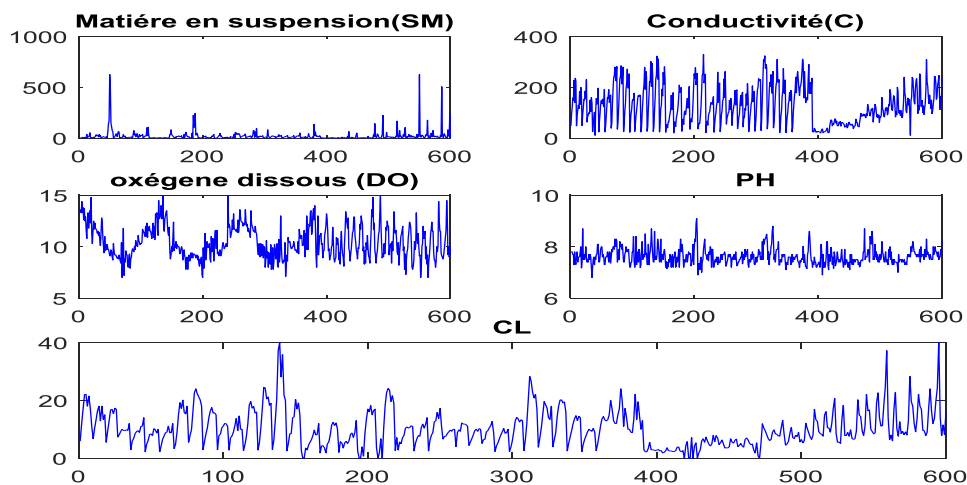


Fig.III.2. L'évolution des cinq paramètres descripteurs.

2.3. Evaluation des performances

Pour une évaluation des performances des trois modèles précédemment testés, définissons quelques mesures statistiques.

Soient :

- Racine de l'erreur quadratique moyenne (REQMA)

$$\text{REQMA} = \left(\frac{1}{n} \sum_{i=1}^n e^2(i) \right)^{\frac{1}{2}} \quad (\text{III.1})$$

- Erreur absolue moyenne (EMA) :

$$\text{EMA} = |e(i)| \quad (\text{III.2})$$

- Erreur quadratique moyenne de généralisation (EQMA) :

$$\text{EQMA} = \left(\frac{1}{n} \sum_{i=1}^n e^2(i) \right) \quad (\text{III.3})$$

Ou : $e(i) = y_r(i) - y_{e/c}(i)$, tel que : y_r : sortie réelle, $y_{e/c}$: sortie calculée (apprentissage) ou estimée (test).

- Le coefficient de corrélation est un coefficient statistique permettant de mettre en évidence, une liaison entre deux types de séries de donnée statistique. Le coefficient de corrélation compris toujours entre -1 et 1.

$$R^2 = \frac{\text{COV}(X,Y)}{\sigma_X \sigma_Y} \quad (\text{III.4})$$

Ou COV(X,Y) désigne la covariance des variables X et Y, σ_X et σ_Y leurs écarts types .

2.3. Modèle Neuronal-RBF

Le réseau de neural-RBF comporte une seule couche cachée dont la fonction d'activation est appelée fonction-noyau ou gaussienne et une couche de sortie avec une fonction d'activation linéaire. Différentes architectures sont testées pour déterminer le nombre adéquat de neurones dans la couche cachée du modèle Neuronal-RBF. Le tableau III.2 montre pour plusieurs architectures de réseaux testés, les résultats correspondants aux différents paramètres d'apprentissage et de test, tels que : le nombre de neurones dans la couche cachée (NNCC), le nombre d'itérations (NI) est fixe (1000), le temps d'apprentissage (t_{appr}), le temps de test (t_{tst}), l'erreur moyen absolue (EMA), l'erreur d'entraînement (EQMA), la racine carrée de l'erreur d'entraînement (REQMA) et la corrélation (R^2).

2.3.1. Résultats d'apprentissage

Les réseaux neuronal-RBF sont testés et validés en utilisant l'algorithme d'apprentissage de Levenberg-Marquardt. Les résultats de l'apprentissage présentés dans le tableau III.2. Les paramètres tels que les différents nombres de neurones dans la couche cachée.

Les bases	NNCC	t_appr (sec)	EMA	EQMA	R ² (%)
Base 1	140	13.572	0.031	0.0024	94.72
	900	27.73	0.017	0.0008	98.29
Base 2	140	14.33	0.028	0.002	95
	900	41.73	0.023	0.0014	97.04
Base 3	140	15.89	0.0027	0.0019	95.5
	900	45.73	0.0023	0.0013	97.08

Tab. III.2. Résultats d'apprentissage (Modèle neuronal-RBF).

On remarque une nette diminution de l'erreur d'entraînement quand il y a augmentée les neurones dans la couche cachée.

2.3.2 Résultats de test

Dans un but de validation de réseau choisi, trois bases de données destinée aux tests. Une évaluation des performances de ces réseaux en matière de temps d'exécution, EMA, EQMA et coefficient de corrélation est donc effectuée. Le tableau III.3 montre ces résultats de test obtenus.

Les bases	NNCC	t_tst (sec)	EMA	EQMA	R ² (%)
Base 1	140	0.202	0.052	0.0069	87
	900	0.28	0.045	0.0065	88.14
Base 2	140	0.22	0.029	0.0021	90
	900	0.40	0.024	0.0018	91.45
Base 3	140	0.3	0.028	0.002	92.36
	900	0.52	0.0027	0.0017	95.60

Tableau.III.3. Résultats de test (Modèle neuronal-RBF).

La figure III.3 montre les résultats de prédiction ponctuelle obtenue sur l'ensemble de test utilisé.




Figure.III.3. Résultats de test du modèle neuronal-RBF.

2.4. Modèle Neuronal-MLP

Nos réseaux utilisés organisés en plusieurs couches, ils comprennent une couche d'entrée, une ou plusieurs couches cachées intermédiaires, et une couche de sortie qui doit restituer l'ensemble des sorties désirées après apprentissage.

2.4.1 Résultats d'apprentissage

Dans ce cas nous avons proposé des architectures de MLP comme montré dans le tableau suivant :

Les bases	NNCC	t_appr (sec)	EMA	EQMA	R ² (%)
Base 1	4-1	18.844	0.029	0.002	90.06
	4-8-1	39.51	0.043	0.001	93.34
	4-8-16-1	79.591	0.009	0.0003	99
Base 2	4-1	23.322	0.046	0.0046	90
	4-8-1	35.615	0.032	0.002	95
	4-8-16-1	82.399	0.012	0.00044	99
Base 3	4-1	18.907	0.042	0.004	90.34
	4-8-1	36.519	0.032	0.0019	95.59
	4-8-16-1	91.01	0.012	0.00037	99.25

Tableau.III.4. Résultats d'apprentissage (Modèle neuronal-MLP).

2.4.2 Résultats de test

Les bases	NNCC	t _{tst} (sec)	EMA	EQMA	R ² (%)
Base 1	4-1	0.54	0.062	0.0088	87.09
	4-8-1	0.57	0.057	0.007	88.14
	4-8-16-1	0.88	0.056	0.0003	89.42
Base 2	4-1	0.53	0.035	0.0022	89.07
	4-8-1	0.59	0.032	0.002	90.02
	4-8-16-1	0.64	0.019	0.0019	92.59
Base 3	4-1	0.60	0.040	0.0050	89.97
	4-8-1	0.651	0.034	0.002	95.85
	4-8-16-1	0.80	0.014	0.00048	98.97

Tableau.III.5. Résultats de test (Modèle neural-MLP).

La figure III.4 montre les résultats de test de modèle MLP

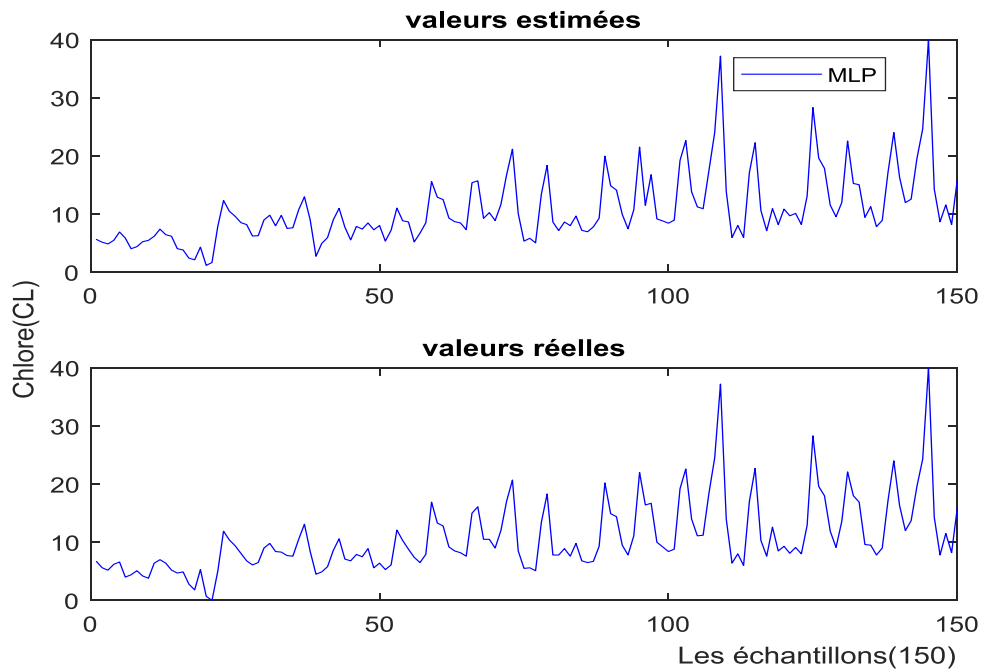


Fig.III.4 Résultats de test de modèle neuronal-MLP.

2.5. Modèle Deep Learning

Dans ce cas nous avons proposé l'architecture de Deep Learning comme montre dans la figure suivante :

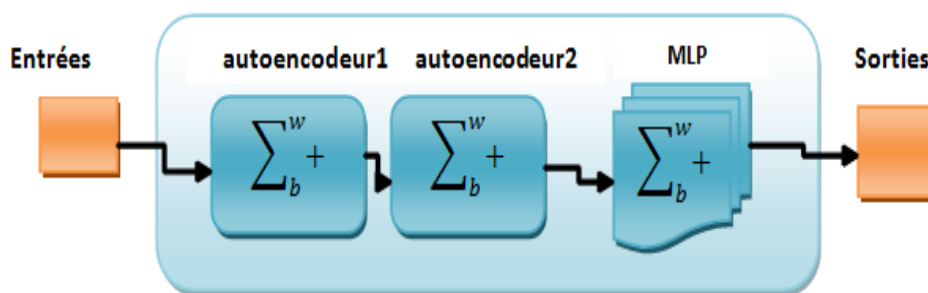


Figure.III.5. L'architecture de Deep Learning utilisé.

2.5.1. Résultats d'apprentissage

Les bases	t-appr (sec)	EMA	EQMA	R ² (%)
Base 1	145.88	0.012	0.0044	99.04
Base 2	190.78	0.011	0.0043	99.08
Base 3	201.3	0.0083	0.00021	99.56

Tableau.III.6. Résultats d'apprentissage (Deep-Learning).

2.5.2. Résultat de test

Le	Les bases	t-appr (sec)	EMA	EQMA	R ² (%)
	Base 1	110.3	0.027	0.0014	97.08
	Base 2	120.54	0.011	0.00037	98.17
	Base 3	201.3	0.0040	0.00004	99.92

Tab. III.7. Résultats de test (Modèle Deep-Learning).

figure III.6 représente les résultats de test(modèle deep learning)




Fig.III.6. Résultats de test (Modèle Deep-Learning).

Les résultats statistiques obtenus pour les trois modèles testés sont récapitulés dans les tableaux III.3, III.5 et III.7. On peut constater que la valeur moyenne des valeurs estimées de

chlore est proche égale à celle calculée sur les données réelles. La bonne corrélation entre le chlore estimé et réel pour les trois modèles est exprimée par les fortes valeurs des coefficients de corrélation.

2.6. Etude comparative

Les bases	Les techniques	Apprentissage				Test			
		t-appr	EMA	EQMA	R ² (%)	t-tst	EMA	EQMA	R ² (%)
Base 1	RBF	27.23	0.017	0.0008	98.26	0.28	0.045	0.0065	88.14
	MLP	79.59	0.009	0.0003	99	0.64	0.056	0.0003	89.42
	Deep Learning	145.8	0.012	0.00044	99.04	110.3	0.027	0.0014	97.8
Base 2	RBF	41.73	0.023	0.0014	97.04	0.4	0.024	0.0018	91.45
	MLP	82.39	0.012	0.0044	99	0.80	0.019	0.0019	92.59
	Deep Learning	190.78	0.011	0.0043	99.08	120.54	0.011	0.00037	98.17
Base 3	RBF	45.73	0.0023	0.0013	97.08	0.52	0.0027	0.0017	95.6
	MLP	91.01	0.012	0.0037	99.25	0.88	0.014	0.00048	98.97
	Deep Learning	201.3	0.0083	0.00021	99.56	201	0.0040	0.00004	99.92

Tab.III.8. Tableau comparatif des caractéristiques des modèle MLP, RBF et Deep Learning.

Discussion des résultats

A travers les résultats de simulation obtenus dans les tests de validation des trois techniques MLP, RBF et Deep Learning, on déduit les résultats suivants :

La base le plus grand (Base 3) donne les meilleurs résultats soit dans la phase d'apprentissage ou bien la phase de test. La phase d'apprentissage des trois techniques (RBF, MLP et Deep Learning) présentent des coefficients de corrélations R^2 égales à 0.97, 0.992 et 0.995 alors que pour la phase de test la technique Deep Learning donne un coefficient de corrélations égal à 0.992, ce qui est plus grand que ceux de deux autres techniques (MLP et RBF) .

L'erreur quadratique moyenne (EQMA) et l'erreur moyenne absolue des trois techniques dans la phase d'apprentissage et test reste relativement(EQAM) faible.

Etant donné que le modèle Deep Learning est retenue comme étant le meilleur choix, elle est appliquée dans ce cadre pour effectuer un capteur logiciel de chlore.

Le figure III.7 représente les résultats des trois techniques :

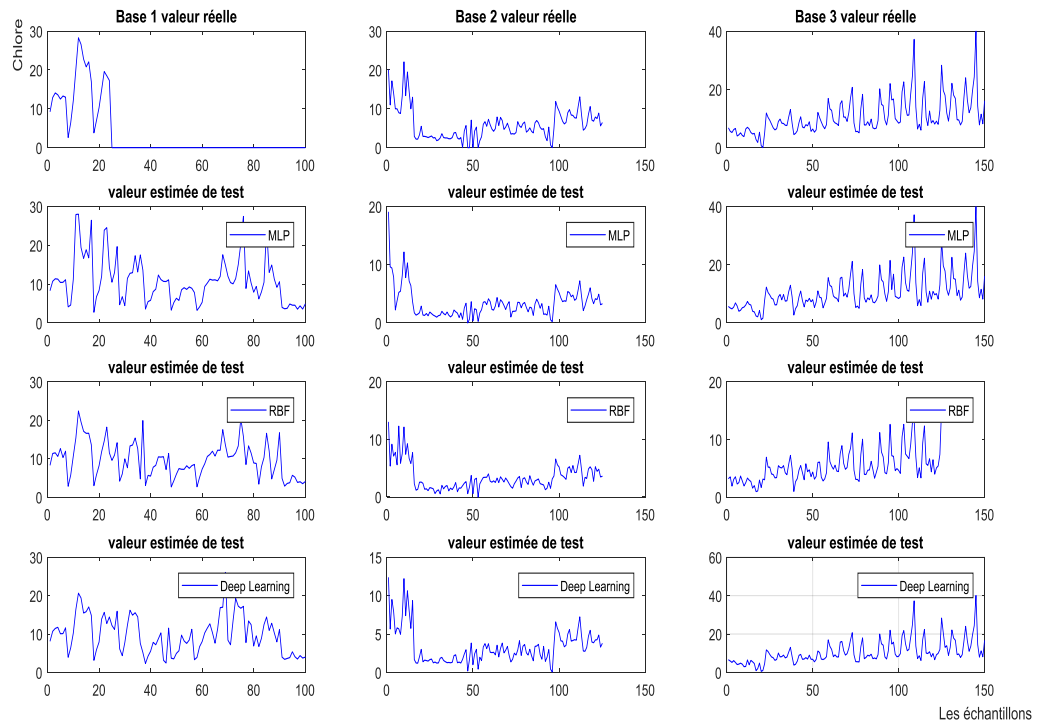


Fig .III.7. Résultats de test des différents modèles.

3. Classification multi-classe

Les méthodes de classification ont pour but d'identifier les classes auxquelles appartiennent des objets à partir de certains paramètres descriptifs. Elles s'appliquent à un grand nombre d'activités humaines et conviennent en particulier au problème de la prise de décision automatisée de classification, où les classes correspondent principalement à deux états bien différents (état potable, état non potable), et les formes représentent les différents états de l'eau obtenus à partir de 4 paramètres descripteurs qui regroupent en 3 classe. On présente d'abord un ensemble de données extraites d'une base réelle et constitué de 800 échantillons.

3.1. La station de production d'eau potable Tilesdit

Le barrage « Tilesdit » est situé géographiquement dans la commune de Bechloul à 20 km du Sud-est de la wilaya de Bouira, Algérie. Ce barrage est situé entre les coordonnées cartographiques et les coordonnées Lambert suivantes (figure III.8) :

- Latitude : 35° 13' 22'' Nord.
- Longitude : 4° 14' 23'' Est.



Fig.III.8. Carte géographique situant le barrage « Tiledit » [Google Maps].

Ce barrage disposant d'un volume de 167 million de mètres cubes d'eau, est conçu de façon à juguler la tension qui persiste dans la distribution d'eau au niveau de 12 communes (figure 3.9). De part son implantation dans la région de Bouira, le barrage Tiledit dont la mise en eau à été effectuée vers la fin de l'année 2005, garantira de l'eau potable aux communes relevant de l'Est et du Sud-Est de la wilaya, c.-à-d: El-Asnam, Bechloul, El-Adjiba, Ahl-Ksour, Oud El-Berdi, Mesdour, Taguedit, Ahnif, Bordj O'khris, Ouled rached, Ath Mansour, Bouira et la zone industrielle de Sidi Khalel. Le transfert d'eau dont le lancement des travaux de réalisation à été prévu au début 2011, est destinée à l'alimentation de cinq autres communes de la daïra de Mansourah, dans la wilaya de Bordj Bou Arréridj. Des travaux sont en cours en vue de raccorder les communes de Takdit et Ait Laaziz, ainsi que d'autres communes rurales du Sud-Est de la wilaya de Bouira au réseau d'alimentation de ce barrage, qui devrait s'étendre jusqu'à Hammam k'sana. Parallèlement, la même direction a prévu 12 opérations portant sur la réalisation de réseaux AEP, en plus de 12 réservoirs d'une capacité globale de 74000 m³ d'eau en vue de l'amélioration de l'approvisionnement en eau des communes alimentées par ce barrage notamment avec un débit de 72650 m³/jour. Il est également important de signaler qu'à l'horizon 2020, ce barrage garantira l'eau en faveur de 307200 habitants, selon les prévisions du secteur de l'hydraulique. Les travaux menés ont porté à 6 le nombre de stations de pompage pour un débit de 41 à 981 l/s. Une station de traitement d'une capacité de 74000 m³/jour, un réservoir d'eau traitée de deux compartiments d'un volume total de 13000 m³ et de 6 réservoirs de capacité allant de 200 à 5000m³.



Fig .III.9.Image représentant le site du barrage « Tiledit » [Google Earth].

L'eau prélevée dans le barrage est pompée jusqu'à la station de traitement. Celle-ci se trouvant au même lieu, est mise en service depuis 2009 (figure III.9). Elle effectue le processus d'épuration à travers les cinq étapes de traitement indiquées au premier chapitre à savoir : le prétraitement, la pré-oxydation, la clarification, la désinfection et l'affinage. L'étape de clarification est assurée par le procédé de coagulation-floculation, décantation et filtration, grâce à un décanteur et un étage de filtration sur sable.



Fig.III.10. Image représentant le site de la station « Tiledit » [Google Earth].

3.2. Description de la base de données

Nous cherchons à décider sur la qualité de l'eau à travers ses paramètres descripteurs. Nous n'avons en fait aucune connaissance a priori sur un type de modèle représentant parfaitement ce procédé, par contre nous pouvons porter notre jugement sur la qualité de cette eau à partir de quelques données descriptives. Il y a quatre (4) paramètres physicochimiques qui sont souvent utilisés dans plusieurs travaux, et qui renseignent sur les dangers majeurs qu'il faut surveiller. Ces paramètres sont collectés à partir de la station Tiledit et qui sont résumés comme suit : pH, Conductivité (C), Température (T°), Turbidité (TU), L'objectif qui se trouve derrière la collecte des données relatives à ces paramètres est de trouver un modèle de classification permettant de distinguer deux états bien distincts de l'eau (état potable et état non potable) dans un premier temps, et trois états différents par la suite après sélection de la technique adoptée. La qualité de cette eau reflétée par sa potabilité repose en fait sur une

corrélation qui ne peut être identifiée que statistiquement. Des données descriptives expérimentales recueillies sur une longue période (plusieurs années) pourraient atteindre cet objectif.

Nous cherchons à appliquer notre approche de surveillance aux paramètres descripteurs de la qualité de l'eau brute fournis par les capteurs de mesure de la station. Notre connaissance du processus de traitement est limitée aux données enregistrées de la station durant les trois années écoulées 2009-2011. Ces mesures proviennent des différentes étapes de traitement, on y trouve : des mesures en continu issues de capteurs physico-chimiques, des analyses faites au laboratoire. Plusieurs paramètres descripteurs de la qualité de l'eau brute mesurés en ligne N quotidiennement à raison de 3 fois/jour, en plus des essais effectués au laboratoire qui sont réalisés chaque semaine. Quatre paramètres descripteurs principaux sont mesurés directement des capteurs vers la station sont : Température, pH, Conductivité et Turbidité.

3.4. Simulation

3.4.1. Modèle Neural-MLP

Comme on essaie de prédire une valeur en utilisant les 800 valeurs précédentes, nous allons donc utiliser un réseau avec deux couches cachées.

3.4.1.1. Les résultats d'apprentissage et de test

NNCC	Taux (%)		Le temps (s)	
	Apprentissage	Test	t-appr	t-tst
4-1	98.6	91.5	124.66	0.624

Tab.III.9. Résultats d'apprentissage et de test (modèle Neuronal-MLP).

3.4.2. Modèle Neuronal-RBF

3.4.2.1. Les résultats d'apprentissage et de test

Dans cette section nous allons présenter les résultats d'apprentissage et de test pour RBF avec 1000 itérations qui été choisis d'une façon aléatoire. De plus, les résultats représente le taux de classification et le temps d'entraînement les deux étapes d'apprentissage et du test comme montre le tableau III.10.

NN	Taux (%)		Le temps (s)	
	Apprentissage	Test	t-appr	t-tst
400	98.6	91.5	124.66	0.624
600	98.5	93	190.78	0.967
800	99.33	98	201.3	0.124

Tab.III.10. Résultats d'apprentissage et de test (modèle Neuronal-RBF).

3.4.3. Modèle Deep Learning

Le tableau 3.11 a été obtenu à partir d'une étude réalisée dans le but de prédire la classe de potabilité, Nous utilisons le modèle Deep Learning.

Configuration	NNCC	Hidden Layer
Configuration 1	4-1	autoencodeur1= 25 autoencodeur2= 10
Configuration 2	4-10-1	autoencodeur1= 100 autoencodeur2= 75

Tab.III.11. Configuration de modèle Deep Learning.

3.4.3.1. Les résultats d'apprentissage et de test

Configuration	Taux (%)		Le temps (s)	
	Apprentissage	Test	t-appr	t-tst
1	99.33	98	45.20	10.02
2	1	99	150.63	40.42

Tableau.III.12. Résultats d'apprentissage et de test (Deep Learning).

3.4.4. Etude comparative

Technique	Taux (%)		Le temps (s)	
	Apprentissage	Test	t-appr	t-tst
MLP	98.6	91.5	124.66	0.624
RBF	99.33	98	201.3	0.124
Deep Learning	1	99.5	150.63	150.42

Tab.III.13. Tableau comparatif des caractéristiques des modèle MLP, RBF et Deep Learning.

À travers le tableau ci-dessus, nous constatons que La phase d'apprentissage des trois techniques (RBF, MLP et Deep Learning) présentent le Taux de classification égales à 0.98, 0.99 et 1 alors que pour la phase de test la technique Deep Learning donne un Taux de classification égal à 0.995, ce qui est plus grand que ceux de deux autres techniques (MLP et RBF).

Le réseau Deep Learning présenté des meilleurs résultats en termes de taux de classification. Donc, nous concluons que les réseaux des neurones de type Deep Learning meilleur et plus efficace dans cette application.

Conclusion

Ce dernier chapitre a fait l'objet d'une étude en simulation concernant la mise en œuvre de trois techniques d'apprentissage statistique neuronal-MLP et, neuronal-RBF et Deep Learning appliquées dans le domaine du contrôle et de surveillance des eaux potables. Cette étude a permis la validation et l'évaluation des performances de chacune de ces méthodes présentées. Une étude comparative dans le but d'un choix décisif de la méthode la mieux adaptée à l'application a été effectuée.

Afin de voir que cette méthode est adaptable à l'application indiquée ; une étude comparative dans le but d'un choix décisif de la méthode la plus adaptée à l'application a été effectuée. La discussion des résultats obtenus des paramètres liés au temps d'apprentissage et de test, à l'erreur d'entraînement et au coefficient de corrélation des trois techniques, a permis d'opter pour la technique Deep Learning retenue pour ses qualités et avantages adaptés au problème posé. Cette technique a fourni de très bons résultats de simulation au développement du capteur logiciel de CL qui présente une solution satisfaisante pour notre problème de régression. Le contrôle et surveillance de potabilité de l'eau. Présentée pour un problème de classification multi-classe, la technique a fourni de très bons résultats de simulation. La base de données réelle provenant de la station Tilesdit de Bouira et appliquée à la technique en question, a montré l'efficacité de cette approche.

CONCLUSION GENERALE

Le travail de recherche présenté dans ce mémoire porte sur l'étude des réseaux de neurones artificiels et à base radiale : RNA et neuronal-RBF respectivement, appliquée à la reconnaissance de formes dans le domaine du contrôle et de surveillance des eaux potables. Dans l'objectif de découvrir laquelle des techniques est la plus efficace, dans ce domaine à partir d'une étude comparative. A cet effet, notre modeste travail peut être considéré comme une contribution aux solutions proposées, pour résoudre des problèmes d'intérêt stratégique à préoccupation nationale, utilisant des outils modernes à base de techniques avancées.

Cette étude a été structurée autour de trois chapitres essentiels. Le premier consacré à une introduction au domaine de l'eau, il a permis de présenter des généralités ainsi que les différentes méthodes de contrôle et de surveillance employées et La notion de capteurs logiciels conçus dans le domaine comme étant un moyen intéressant pouvant remplacer des capteurs physiques, a été aussi présentée.. Dans le second chapitre a été particulièrement dédié aux mécanismes théoriques des méthodes de classification et de régression de données à apprentissage statistique supervisé. Dans ce chapitre, trois modèles (Neuronal, Neuronal-RBF et Deep Learning) fondés sur ce type d'apprentissage ont été exposés.

Enfin le troisième et dernier chapitre, a fait l'objet d'une étude en simulation concernant la mise en œuvre de ces trois modèles d'apprentissage statistique appliqués dans le domaine du contrôle et de surveillance des eaux potables. Cette étude a permis la validation et l'évaluation des performances de chacune des méthodes présentées. Une étude comparative dans le but d'une sélection de la méthode la mieux adaptée à l'application proposée a été effectuée. Les paramètres liés au taux de reconnaissance, au temps d'apprentissage, temps de test coefficient de corrélation et l'erreur d'entraînement, ont été les facteurs pertinents qui ont permis d'évaluer les méthodes étudiées. La discussion des résultats obtenus, a permis d'opter pour la technique Deep Learning retenue pour ses qualités et avantages adaptés au problème posé. Deux exemples de validation basés sur cette technique ont été alors élaborés.

Le développement d'un capteur logiciel de chlore (CL) et le contrôle et surveillance de potabilité de l'eau. Présentée pour un problème de classification, la technique a fourni de très bons résultats de simulation. La base de données réelle provenant de la station Tilesdit de la wilaya de Bouira et appliquée à la technique en question, a montré l'efficacité de l'approche.

La perspective de la mise en œuvre de Deep Learning restent prometteurs et nouveau. La décision du système peut être améliorée par l'exploitation de nouveaux paramètres d'entrée. Les capteurs logiciels peuvent dans ce cas jouer un rôle primordial en se substituant davantage à des paramètres descripteurs chimiques ne pouvant être mesurés en continu. afin de minimiser le nombre des capteurs physiques(le cout). Enfin, cette application montre une alternative prometteuse pour notre pays dans l'avenir pour une surveillance intelligente et automatique de la qualité des eaux potables.

- [1] **Mallevalle J., Odendaal P.E., Wiesner M.R.** « The emergence of membranes in water and waste water treatment » In: Water Treatment Membrane Process, Chapitre 1, McGraw-Hill, 1996 10 p.
- [2] **ABD ERRAZEK .A**, « Surveillance des eaux propres à l'aide des techniques d'intelligence artificielle », thème de master, Université de M'sila.2013.
- [2] L'eau dans les établissements de santé : guide technique du ministère des solidarités, de la sante et de et de la famille en France.
- [3] **LADJAL .M** « Contribution au développement de systèmes de surveillance innovants dédiés au contrôle de la qualité des eaux potables » thèse de doctorat, université de M'sila 2013.
- [4] **SLIM .A** « contribution de l'analyse multivariée a l'étude de régression et la classification supervisée des données environnementales » mémoire de master, université de m'sila 2012.
- [5] **Heddam .S** «Contribution à la modélisation de la qualité des eaux par les réseaux de neurones» mémoire de magister, 2006.
- [6] **SALGHI .R** «chimie des eaux», cours, l'Ecole Nationale des Sciences Appliquées d'Agadir.
- [7] **DJAIDJA .A** « Etude de la classification supervisée des données environnementales à l'aide de réseaux de neurones de fonctions à base radiales », mémoire de master, université de m'sila 2016.
- [8] <http://www.sedud.fr/metiers-cycle-eau.php>.
- [9] **Dominique .M, Ceres-Erti .L** « chimie des eaux douces origine naturelle et pollution ».
- [10] l'alimentation en eau potable. France : cahier pédagogique.
- [11] **Kouidri .N** «Etude et traitement de l'eau du barrage djorf-eltorba » mémoire magister, Université Hassiba Benbouali de chlef, 2006.
- [12] **Thévnot C.D**, Chap. 5: Production d'eau potable. France, 49p, 2005.
- [13] Anonyme, Appui a la mise en place d'un système de surveillance et de contrôle de qualité pour l'eau de boisson dans les sites de déplacés et de camps de réfugiés à l'est de Tchad, 2008.
- [14] **Asch .G, Poussery .B**, les capteurs en instrumentation industrielle, 28p.
- [15] **Ameziane .A** «Contribution a la mise en place d'un système multi capteurs pour la surveillance des eaux de surface: fusion de données et aide a la décision », thèse doctorat, l'université henri poincaré, nancy 1,2005.

- [16] **N. VALENTIN** «Construction d'un capteur logiciel pour le contrôle automatique du procédé de coagulation en traitement d'eau potable» thèse de doctorat 2000.
- [17] **Hernández H. R** «Supervision et diagnostic des procédés de production d'eau potable », thèse doctorat, Laboratoire d'Analyse et d'Architecture des Systèmes du CNRS, 2006.
- [18] **Lin.B, Recke .B, Knudsen J. K.H, Jørgensen S. B**, A systematic approach for soft sensor development.
- [19] Computers and Chemical Engineering 31 (2007) 419–425.
- [20] **Hadid .B** «Développement de capteurs logiciels pour procédés industriels par estimation paramétrique », thèse doctorat, Université de Poitiers, 2014.
- [21] **Zribi .M, Boujelbene .Y**« Les réseaux de neurones un outil de sélection de variables : Le cas des facteurs de risque de la maladie du cancer du sein », Université de Sfax, Tunisie, thèse doctorat, 2012.
- [22] **BENZINEB .K** « modélisation des débits de crues du bassin de oued ouahrane par les reseaux de neurones artificiels», Université Hassiba Benbouali de Chlef, thèse doctorat, 2017.
- [23] **Boniface.Y, Rougier N. P**, Apprentissage et Mémoires Introduction aux réseaux de neurones artificiels, 2012.
- [24] **PETITJEAN .G**, introduction aux réseaux de neurones.
- [25] **BENNANI .Y**, Apprentissage par réseaux de neurones artificiels, 2014.
- [26] **HAMMOUCHE .Y**, 'Comparaison de plusieurs méthodes pour la prédiction de la Charge Electrique Nationale', mémoire de magistère, Université de Badji Mokhtar Annaba, 2009.
- [27] **AMMAR .M .Y**, 'mise en œuvre de réseaux de neurones pour la modélisation de cinétiques réactionnelles en vue de la transposition batch/continu', Ecole Nationale d'Ingénieurs de Sfax, Tunisie, thèse de doctorat, 2007.
- [28] **Djeriri .Y**, Les Réseaux de Neurones Artificiels, 2017.
- [29] **Wira .P**, Réseau de Neurone Artificiel : Architecture et application, France, Université Haute Alsace, 2009.
- [30] **ABDESSALEM .C** « Optimisation de procédés de mise en forme par les réseaux de neurone artificiels », thèse doctorat, Laboratoire de Génie Mécanique, Ecole Nationale d'Ingénieurs de Monastir, Tunisie, 2007.
- [31] **Parizeau .M**, Réseaux de Neurones, Université de Laval, 2004.

- [32] **BEN RAHMOUNE .M** «Diagnostic des défaillances d'une turbine a gaz a base des réseaux de neurones artificiels pour l'amélioration de leur système de détection des vibrations, thèse doctorat », Université de Djelfa, 2017.
- [33] **THIAW .L** «Identification de systèmes dynamiques non-linéaires par réseaux de neurones et multimodales », thèse doctorat, Université Paris, 2008.
- [34] **LAROUCHE .E** «exploration de différentes architectures de réseau de neurone pour la prédiction de la glace atmosphérique sur les conducteurs des réseaux de neurone » mémoire master, Université de Québec, 2002.
- [35] **Broomhead .D.S, Lowe .D**, Multivariate functional interpolation and adaptive networks, "Complex Systems, vol 2, p.321-355, 1988.
- [36] **J. Moody .J, Darken C.J**, Fast Learning in Network for Locally Tuned Processing Units, Neural Computation, vol.1, p.281-294, 1989.
- [37] **Poggio .T, Girosi .F**, "Network for approximation and learning," Proc. IEEE, vol 78, no. 9, pp. 1481 -1497, 1990.
- [38] **TOUZET .C** « les réseaux de neurones artificiels, introduction au connexionnisme» cours, exercice et travaux pratiques, paris, juillet 1992.
- [39] **KCHEMACHEMA .K** «Etude des structures microbandes par La technique des réseaux de neurones Application a différentes excitations », Thèse de Doctorat, Université de Constantine 1, 2013.
- [40] **Youcef .M.D** «Deep Learning pour la classification des images », mémoire de master, Université Abou Bakr Belkaid. Tlemcen, 2017.

RESUME

L'eau est très importante dans la vie. Il est donc nécessaire de la contrôler, la surveiller pour la rendre potable. Dans ce cadre des efforts ont été effectués durant ces dernières années, pour développer des méthodes de contrôle et de surveillance automatique de l'eau. Ce travail s'inscrit dans ce courant de recherche, en proposant une nouvelle approche pour le contrôle et la surveillance de la qualité des eaux potables. Ce mémoire aborde le problème de la surveillance des eaux potables en fonction des caractéristiques physico-chimiques de l'eau brute à l'aide d'un modèle basé sur les techniques de l'apprentissage statistiques telles que : les **PMC**, **RBF** et **Deep Learning**, appliquées au développement du capteur logiciel **CL** vu comme problème de régression et le contrôle de potabilité de l'eau en tant que problème de classification. et d'évaluer les performances de chacune après une simulation à l'aide du logiciel MATLAB pour avoir la technique la plus adaptée.

ABSTRACT

Water is very important in life. It is therefore necessary to control it, monitor it to make it drinkable. In this context efforts have been made in recent years to develop methods of control and automatic monitoring of water. This work is part of this trend of research, proposing a new approach for the control and monitoring of drinking water quality. This thesis addresses the problem of drinking water monitoring according to the physicochemical characteristics of raw water using a model based on statistical learning techniques such as: **PMC**, **RBF** and **Deep Learning**, applied to the development of the software sensor CL seen as a problem of regression and the control of potability of water as a problem of classification. and to evaluate the performances of each after a simulation using the software MATLAB to have the adapted technique.

ملخص

الماء مهم جدا في الحياة. لذلك من الضروري السيطرة عليه ومراقبته لجعله صالح للشرب. في هذا السياق، بذلت جهود في السنوات الأخيرة لتطوير طرق المراقبة والمراقبة الآلية للمياه. هذا العمل جزء من اتجاه هاذا البحث ، يقترح منهجاً جديداً للتحكم في جودة مياه الشرب ومراقبتها. تتناول هذه الرسالة مشكلة مراقبة مياه الشرب وفقاً للخصائص الفيزيائية الكيميائية للمياه الخام باستخدام نموذج يعتمد على تقنيات التعلم الاحصائية **PMC** و **RBF** و **Deep Learnin** ، يتم تطبيقه على تطوير مستشعر البرنامج الكلور الذي ينظر إليه على أنه مشكلة تنبؤ والتحكم في إمكانية شرب الماء كمشكلة تصنيف. للحصول على تقنية الأكثر تكيف بعد المحاكاة باستخدام برنامج MATLAB.