

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

BADJI MOKHTAR-ANNABA UNIVERSITY
UNIVERSITE BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Faculté des Sciences de l'Ingénieur
Département de l'Electrotechnique

Année 2012/2013

MEMOIRE

Présenté en vue de l'obtention du diplôme de **Magister**

Modélisation des défaillances et leur diagnostic par les méthodes de reconnaissance des formes floue

Option
Commande

Par
HANDIS Moufida

Devant le Jury :

Président :	DEBBACHE Nacer Eddine	Pr - Université d'Annaba
Directeur de mémoire :	LAKEL Rabah	M.C.A - Université d'Annaba
Examineurs :	BAHI Tahar	Pr - Université d'Annaba
	RAMDANI Messaoud	M.C.A - Université d'Annaba

ملخص

إن تشخيص إختلالات الأنظمة الصناعية ما فتئ يشكل محل اهتمام الصناعيين أو الباحثين العلميين. إن الهدف الرئيسي للتشخيص هو تحديد وتعريف الخلل أو الضعف الذي يطرأ على النظام, وذلك في إطار مقارنة تمكن من المتابعة الآنية لكل تغير في حالة تشغيل النظام من وضعية عادية إلى وضعية غير عادية (مختلة).

لا يمكن في جميع الأحوال إعداد نموذج رياضي لتمثيل التغيرات الممكنة لحالة تشغيل نظام ما. كل بديل يمكن اللجوء إلى الطرق التي لا تعتمد على النماذج الرياضية, وإنما تركز على استغلال العناصر (المتغيرات) المحددة لحالة النظام, والتي تمكن من معرفة التحولات التي تطرأ على النظام الصناعي.

في بحثنا هذا تم اختيار طريقة المعرفة غير الجلية للأشكال من أجل تشخيص الإختلالات الممكنة في الأنظمة الصناعية .

تم تطبيق منهجية التشخيص المعتمدة على محطة معالجة المياه بتاكسابت المتواجدة بولاية تيزي وزو. كلمات مفتاحية: النمذجة و تشخيص الإختلالات, المعرفة غير الجلية للأشكال, محطة معالجة المياه.

Abstract

Failures diagnosis in industrial systems is of great interest both to the world of industry and to scientific researchers. The great purpose of diagnosis is to locate and identify failures which may arise in the system, under supervision approach by allowing to monitor instantly the progression from normal operation mode to abnormal mode.

There is not always guarantee to find mathematical model which can describe the system state operation. A more efficient diagnosis requires methods without models allowing from historical data to be known instantly system state operation.

Fuzzy Pattern Recognition method was retained in present study for diagnosis of industrial systems.

The methodology adopted was applied in the wastewater treatment plant of TAKSEBT located in the wilaya of TIZI OUZOU.

Keywords: Modeling and diagnosis failure, fuzzy pattern recognition, wastewater treatment plant.

Résumé

Le diagnostic des défaillances des systèmes industriels présente un grand intérêt tant pour le monde industriel que pour les chercheurs scientifiques. Le but majeur du diagnostic consiste à localiser et identifier les défaillances qui peuvent surgir dans le système, dans le cadre d'une approche de surveillance permettant de suivre instantanément l'évolution d'un mode de fonctionnement normal vers un mode anormal.

L'obtention d'un modèle mathématique pouvant traduire l'évolution de l'état de fonctionnement d'un système n'est pas toujours évidente. Une alternative fait appel aux méthodes sans modèles permettant à partir des données historiques relatives aux descripteurs du système, de connaître en temps réel le mode de fonctionnement du processus industriel.

La méthode de reconnaissance des formes floue (RdF) à été retenue dans le présent travail pour le diagnostic des défaillances dans les systèmes industriels.

La méthodologie de diagnostic adoptée a été appliquée à la station de traitement des eaux de TAKSEBT située dans la wilaya de TIZI OUZOU.

Mots clés: Modélisation et diagnostic des défaillances, reconnaissance des formes floue, station de traitement des eaux.

A mes chers parents

A mon cher mari,

A mes frères et mes sœurs

A toute ma famille et à mes amies

Je dédie ce travail

Remerciements

J'exprime ma profonde reconnaissance et mes vifs remerciements à mon directeur de mémoire en l'occurrence monsieur LAKEL Rabah, Maître de conférences à l'université d'Annaba, qui a su me faire profiter de son expérience professionnelle. À cet effet, je tiens à souligner ses conseils précieux et enrichissants qu'il m'a prodigués durant toute la période de préparation du présent travail.

J'adresse toute ma reconnaissance au Mr. N-E. DEBBACHE, professeur à l'université d'Annaba, qui m'a fait l'honneur de présider le jury, d'avoir accepté l'examen de mon mémoire.

J'exprime mes vifs remerciements aux membres du jury Mr T. BAHI, Professeur à l'université d'Annaba et Mr M. RAMDANI, Maître de conférences à l'université d'Annaba, qui m'ont fait l'honneur d'examiner ce modeste travail.

Mes vifs remerciements vont également à monsieur A. OMEIRI, chef du département d'électrotechnique à l'université d'Annaba pour ses conseils et encouragements.

J'exprime ma sincère reconnaissance envers monsieur L. OUERDACHI, Maître de conférences et monsieur H. BOUTAGHANE, chargé de cours à l'université d'Annaba, pour leur soutien et surtout leurs grandes qualités humaines.

Je tiens également à adresser mes remerciements à monsieur M. HAMITTOCH, enseignant au département de génie de l'environnement relevant de l'université de Boumerdes, pour l'aide précieuse qu'il m'a apportée pour la collecte des données pratiques ayant servies à la finalisation de ce travail.

Enfin, je remercie tous ceux qui m'ont aidé de près ou de loin, que ce soit par leur sympathie, leurs conseils ou leur soutien moral. Qu'ils trouvent dans ces quelques lignes l'expression de ma profonde gratitude.

Table des matières

Liste des tableaux	1
Liste des figures	2
Notations	4
Acronymes	5
Introduction générale	6
Chapitre 1: Terminologie et principe du diagnostic des systèmes industriels	9
1.1. Introduction	10
1.2. Concepts et terminologie	11
1.3. La supervision et le diagnostic	13
1.4. Les différentes méthodes de diagnostic	15
1.4.1. Méthodes à base de modèles	16
1.4.1.1. Modèles causaux qualitatifs	16
1.4.1.2. Méthodes à base de modèles quantitatifs	17
1.4.2. Méthodes sans modèles	18
1.4.2.1. Méthodes qualitatives	19
1.4.2.2. Méthodes quantitatives	20
1.5. Conclusion	24
Chapitre 2: Méthodes de reconnaissance des formes floue	25
2.1. Introduction	26
2.2. Procédure de diagnostic par reconnaissance des formes	27
2.2.1. Détermination de l'espace de représentation	27
2.2.1.1. Réduction de l'espace de représentation	28
2.2.1.1.1. Extraction de variables	28
2.2.1.1.2. Sélection de variables	31
2.2.2. Structuration de l'espace de représentation	34
2.2.3. Choix d'une méthode de décision	35
2.2.4. Exploitation du système de diagnostic	38
2.3. Reconnaissance des formes floue	39
2.3.1. Approche floue	39
2.3.2. Méthodes floues de classification supervisée	44
2.3.3. Classification non supervisée	45
2.3.3.1. Algorithme FCM	45

2.3.3.1.1. principe.....	46
2.3.3.1.2. Avantages et inconvénients.....	48
2.3.3.2. Les variantes des C moyennes floues.....	50
2.3.3.2.1. Approche de GK.....	50
2.3.3.2.2. Approche de C moyennes possibilistes.....	51
2.3.3.2.3. Approche de C moyennes possibilistes modifiée.....	53
2.3.3.3. Les problèmes en classification.....	54
2.3.3.3.1. Validation du nombre des classes.....	53
2.3.3.3.2. Méthodes d'initialisation de la partition.....	55
2.3.4. Modélisation des modes de fonctionnement.....	55
2.3.5. Règle de décision.....	57
2.4. Conclusion.....	59
Chapitre 3: Application de la méthode à la station de production de l'eau potable de TAKSEBT	62
3.1. Introduction.....	63
3.2. Description de la station.....	64
3.2.1. Capacité de la station.....	64
3.2.2. Qualité de l'eau à l'entrée de la station.....	65
3.2.3. Qualité de l'eau à la sortie de la station.....	66
3.2.4. Exploitation de la station.....	66
3.2.4.1. Les étapes du traitement de l'eau.....	66
3.2.4.1.1 Dissipation, mélange et réparation.....	67
3.2.4.1.2. La coagulation & floculation.....	68
3.2.4.1.3. La décantation.....	71
3.2.4.1.4. La filtration.....	73
3.2.4.1.5. Désinfection et stockage de l'eau traitée.....	75
3.2.5. Aspects fonctionnels de la station.....	77
3.3. Résultats liés au diagnostic de la station.....	77
3.3.1. Phase d'apprentissage hors ligne (classification des données).....	78
3.3.2. Phase de reconnaissance en ligne.....	82
3.4. Conclusion.....	88
Conclusion générale.....	90
Références bibliographiques.....	92

Liste des tableaux

2.1. Principales t-normes et t-conormes [GRI 07].....	43
2.2. Critères de validité des classes.....	54
3.1. Valeurs contractuelles relatives aux caractéristiques de l'eau produite.....	65
3.2. Description des modes de fonctionnement de la station.....	81
3.3. Degrés d'appartenance du vecteur t_1	83
3.4. Degrés d'appartenance du vecteur t_2	84
3.5. Classe des données objet du rejet en ambiguïté (classe a).....	86
3.6. Degrés d'appartenance associés à la classe a.....	86
3.7. Classe des données objet du rejet en distance (classe d).....	87
3.8. Degrés d'appartenance associés à la classe d.....	87

Liste des figures

1.1. Ordonnancement des anomalies selon leur criticité.....	13
1.2. Les différentes étapes de la supervision.....	15
1.3. Classification des méthodes de diagnostic.....	16
1.4. Principe de diagnostic basé sur la génération des résidus.....	18
1.5. Structure d'un système expert.....	19
1.6. Schéma général d'un neurone.....	21
1.7. Fonctions d'activation les plus utilisées: (a) fonction à seuil, (b) fonction linéaire, (c) fonction sigmoïde, (d) fonction gaussienne	21
1.8. Principe de la reconnaissance des formes.....	23
2.1. Les étapes d'une procédure de la reconnaissance des formes.....	27
2.2. Cheminement pour la détermination de l'espace de représentation.....	28
2.3. Les différentes méthodes de coalescence.....	35
2.4. Rejet en ambiguïté.....	36
2.5. Rejet en distance.....	36
2.6. Structure d'un système de diagnostic par RdF.....	39
2.7. Concept d'appartenance au sens classique et au sens flou	40
2.8. Principaux éléments caractéristiques d'un sous ensemble flou F.....	41
2.9. Mesures de distance pour la classification.....	46
2.10. Exemple de deux classes symétriques.....	48
2.11. Exemple illustratif de deux points l'un est plus éloigné que l'autre des centres des deux groupes.....	49
2.12. Exemple illustratif des points inutiles qui peuvent affecter la forme des fonctions d'appartenance.....	49
2.13. Principe de règle du maximum d'appartenance.....	57
2.14. Principe de règle de seuillage d'appartenance.....	58
3.1. Ouvrage de répartition d'eau.....	68
3.2. Eau brute additionnée de coagulant.....	70
3.3. Schéma de la décantation naturelle	72
3.4. Filtres de la station.....	73
3.5. Fonctionnement des BUSELURES lors de la phase de lavage air+eau.....	74
3.6. Schéma Général de l'usine de traitement d'eau potable de la station TAKSEBT...	76

3.7. Evolution du pH.....	78
3.8. Evolution de la turbidité d'entrée (NTU).....	79
3.9. Evolution de la turbidité de sortie (NTU).....	79
3.10. Evolution du taux du coagulant (sulfate d'alumine).....	79
3.11 Evolution de la température.....	80
3.12. Résultats du programme (classification des données).....	80
3.13. Profils de classes.....	81
3.14. Modes de fonctionnement de la station (année 2010).....	82
3.15. Classification d'une nouvelle observation t1 (cas de rejet d'ambiguïté).....	83
3.16. Classification d'une nouvelle observation t2.....	84
3.17. Evolution des cinq paramètres de la station durant la période hivernale 2011.....	85
3.18. Reconnaissance en ligne des données (période hivernale 2011).....	86
3.19. Reconnaissance en ligne du fonctionnement de la station durant: 90 jours de la période hivernale 2011.....	88

Notations

X_f	Vecteur forme
d	Dimension du vecteur forme
R^d	Espace de représentation
d'	Dimension réduite de l'espace de représentation
X_a	Ensemble d'apprentissage
\bar{X}	Moyenne de l'ensemble d'apprentissage
N	Nombre de vecteur de l'ensemble d'apprentissage
M	Nombre de classes
i, j	Indice relatif aux observations
X_i	$i^{\text{ème}}$ élément de l'ensemble d'apprentissage
k, l	Indices relatifs à un numéro de classe $k, l = 1 \dots M$
ω_k	Dénomination de la classe k
ω_a	Classe fictive des vecteurs rejetés en ambiguïté
ω_d	Classe fictive des vecteurs rejetés en distance
U	Matrice de partition floue de dimension $N * M$
$u_{i,k}$	Degré d'appartenance de l'objet i à la classe k .
V	Ensemble des centroïdes des classes
V_k	Centre de la classe k
m	Indice du flou
X	Nouvelle observation
T	Nombre maximal des itérations
t	Compteur des itérations
ϵ	seuil d'arrêt
$\tilde{\Sigma}_k$	Matrice de covariance floue de la classe k
M^*	Nombre optimal des classes
s_k	Seuil d'appartenance associé à la classe k
$D(X)$	Règle de décision
T_a	Seuil de réglage du rejet en ambiguïté.
R	Rapport d'appartenance

Acronymes

RdF	Reconnaissances des formes
RNA	Réseau de neurones artificiel
ACP	Analyse en composantes principales
FCM	Fuzzy C- Means
FCC	Fuzzy C- Covariance
HCM	Hard C- Means
PCM	Possibiliste C- Means
MPCM	Modified Possibilistic C-Means
2D	Deux dimensions
MES	Matières En Suspension
OMS	Organisation Mondiale de la Santé

Introduction générale

Aujourd'hui, les systèmes industriels sont de plus en plus complexes et sophistiqués. Il faut les surveiller en permanence pour prévenir tout incident, améliorer la qualité du produit ou du service, assurer la sécurité du bien ou des personnes. Cette surveillance doit, à chaque instant, vérifier la présence ou l'absence des défauts dans le système puis, en cas de défaut avéré, doit le diagnostiquer. La fonction de diagnostic consiste à détecter une défaillance, de localiser son origine et de déterminer ses causes. Ceci permet d'envisager des actions correctives pour que le système retourne à son fonctionnement nominal.

Dans ce souci, le diagnostic a suscité et continue de susciter un grand intérêt tant au niveau du monde industriel que dans la recherche scientifique. En effet, De nombreuses méthodes sont à la base des travaux en diagnostic par les différentes communautés de recherche en automatique, productique et intelligence artificielle. Ces méthodes se différencient par rapport au type de connaissance a priori sur le système qu'elles nécessitent. Ainsi, elles peuvent être classées, de façon générale, comme des méthodes à base de modèles qui se basent sur l'existence d'un modèle du système à surveiller et les approches sans modèles qui s'appuient sur les connaissances et raisonnement des experts ou sur les données historiques du système.

Le principe des méthodes avec modèles repose sur la comparaison du comportement prévu par le modèle avec le comportement réellement observé du système. Tout écart entre ces deux comportements sera synonyme de défaut. La seconde famille des méthodes, basée sur les données, fait l'hypothèse que certaines données historiques du procédé sont disponibles et exploitables. Dans ce cas, beaucoup de méthodes peuvent être employées, nous distinguons la méthode des systèmes experts, les réseaux de neurones artificiels et les méthodes de reconnaissance des formes,...etc.

En ce qui concerne les approches par reconnaissance des formes, des travaux récents ont été menés au niveau de la supervision et de la surveillance des systèmes complexes.

Les travaux, plus particulièrement axés sur les bio-procédés et les processus de traitement des eaux, ont abordé les problèmes liés à l'interprétation des données et à l'extraction des informations à partir d'une méthode de classification par reconnaissance des formes.

Notre travail se situe dans un contexte similaire, puisqu'il porte sur la modélisation des défaillances dans les systèmes industriels, où l'obtention d'un modèle mathématique pouvant traduire l'évolution du processus n'est pas toujours évidente. Notre contribution consiste à proposer une stratégie permettant, à partir des données disponibles et à l'aide d'une méthode de classification basée sur la reconnaissance des formes floue (RdF), de connaître en temps réel le mode de fonctionnement qui le caractérise, y compris les situations affichant une défaillance éventuelle.

La RdF se base sur la classification des formes en les comparant à des formes types. Une forme est l'observation du fonctionnement du processus, représentée par un point dans un espace à a paramètres appelé l'espace de représentation. Le concept de logique floue est inclus pour mieux considérer l'imprécision. Les formes types que l'on souhaite distinguer correspondent à des sous-ensembles flous appelés *classes*.

Le diagnostic par RdF est réalisé en utilisant une méthode de classification qui associe une nouvelle observation à une classe correspondant à un mode de fonctionnement donné. Nous nous sommes intéressés aux méthodes de classification non-paramétrique, plus adaptées aux cas industriels, pour lesquelles la densité de probabilité est complètement inconnue.

Ce mémoire est structuré en trois chapitres:

Dans le premier chapitre, nous exposerons les différents concepts liés au diagnostic rencontré dans la littérature et employés dans ce mémoire. Nous présentons ainsi le diagnostic dans le cadre d'une procédure plus complète désignée sous le nom de supervision, en mettant l'accent sur les différentes étapes qui s'y rapportent. Nous aborderons par la suite les différentes méthodes de diagnostic de défaillances développées par les différentes communautés de recherche.

Le deuxième chapitre sera consacré à la représentation détaillée de la méthode de reconnaissance des formes floue. Un exposé des différentes étapes de diagnostic par RdF y sera présenté. Nous monterons ainsi dans ce chapitre les différents algorithmes de classification utilisés pour la détermination des modes de fonctionnement du système industriel tout en mettant en lumière les avantages et les inconvénients de chaque algorithme. Nous terminerons ce chapitre par une représentation des règles de décision floues appliquées pour la classification de nouvelles observations permettant de faire une reconnaissance en ligne du comportement du système.

Dans le dernier chapitre de ce mémoire, nous traiterons un exemple applicatif de la méthode de reconnaissance des formes floue qui portera sur le diagnostic de la station de

traitement des eaux de TAKSEBT située dans la wilaya de TIZI OUZOU. Nous présenterons les caractéristiques générales et le principe de fonctionnement de cette station. Nous terminerons ce chapitre par la représentation des résultats obtenus lors de l'application du programme de calcul que nous avons développé en MATLAB 7, en se référant à la méthodologie proposée dans le deuxième chapitre concernant l'apprentissage hors ligne et le diagnostic en ligne du comportement de la station à partir des descripteurs de la station.

Terminologie et principes du diagnostic

Chapitre 1:

Terminologie et principes du diagnostic des systèmes industriels

1.1. Introduction

Le diagnostic des défaillances des systèmes industriels permet de détecter, identifier et localiser un mode de fonctionnement anormal ce qui permettra d'introduire une commande susceptible de revenir à un mode de fonctionnement plus adapté à la mission pour laquelle ce système a été conçu. Il est donc un élément essentiel d'un système de production ou d'un système conçu pour être utilisé par un tiers.

Dans ce chapitre, après un rappel des divers concepts et terminologie propre au diagnostic, nous présenterons le diagnostic dans le cadre d'une procédure plus complète désignée sous le nom de supervision, puis nous l'aborderons indépendamment de toute méthodologie. Nous terminerons ce chapitre par un exposé de différentes méthodes de diagnostic industriel.

1.2. Concepts et terminologie

Il est intéressant, dans un premier temps, de rappeler les principaux termes utilisés en diagnostic des systèmes. Reposant principalement sur le travail effectué par [ADR 00] et [ALH 05], ainsi que sur l'étude de l'ouvrage [BRU 90], un nombre non exhaustif de définitions sont proposées afin de clarifier la suite de ce document, sachant qu'il est courant de trouver dans la littérature internationale des définitions différentes d'une même notion.

- **Fonctionnement normal d'un système**, le fonctionnement d'un système est dit normal lorsque le système est capable de fournir les fonctions pour lesquelles il a été conçu.
- Une **anomalie** permet de décrire tout qui n'est pas conforme à une référence.
- Une **dégradation** représente une perte de performances des fonctions assurées par le système.
- Un **défaut** est une anomalie comportementale au sein d'un système.
- Une **défaillance** définit une anomalie fonctionnelle au sein d'un système physique, c'est-à-dire caractérise son incapacité à accomplir certaines fonctions qui lui sont assignées. Une défaillance est un défaut particulier se traduisant non seulement par une anomalie comportementale, mais aussi par le non respect d'une ou plusieurs fonctions du système physique. Inversement, un défaut n'induit pas nécessairement une défaillance mais peut présager d'une défaillance à venir.
- Une **panne** est l'inaptitude d'un dispositif à accomplir une fonction requise. Dès l'apparition d'une défaillance, caractérisée par la cessation du dispositif à accomplir sa fonction, le dispositif sera déclaré en panne. Par conséquent, une panne résulte toujours d'une défaillance.

Un défaut est naturellement caractérisé par le degré de gravité lié au stade auquel il est détecté. Les défauts peuvent être purement aléatoires (défauts cataleptiques) ou progressifs dans le cas du vieillissement ou de l'usure (défauts évolutifs) et classés par ordre de gravité [ADR 00].

- *Défaut déclaré*

Un défaut déclaré apparaît de façon spontanée et se manifeste souvent par un biais pouvant avoir diverses origines comme une panne de capteur ou d'actionneur. Dans ce cas l'organe en question ne répond plus aux excitations du phénomène physique auquel il est soumis et délivre constamment à sa sortie une valeur fixe souvent nulle. Ceci peut être dû à un encrassement, à un mauvais étalonnage du capteur ou à un état détérioré d'un composant du système.

- *Défaut naissant*

Un défaut naissant apparaît de manière progressive et est d'amplitude croissante. Il se présente sous la forme de dérives souvent dues au vieillissement ou à l'usure.

- *Défaut ponctuel*

Un défaut ponctuel ou passager se caractérise par une durée brève et un écart significatif par rapport à la moyenne locale. Ses origines sont le plus souvent localisées au niveau des systèmes de collecte et de transport des mesures (parasites électromagnétiques, ...).

- *Panne catastrophique*

Une panne catastrophique entraîne un arrêt du système.

Les défauts ou pannes sont classés selon leur origine. La modification des relations de cause à effet peut provenir de l'observation que l'on a du phénomène (capteur) ou encore de la cause que l'on croit appliquée au processus (organe de commande) ou du processus lui-même (fuite, encrassement, rupture d'organe,...) [BRU 90].

Nous avons ainsi:

- Défaut ou panne de capteurs,
 - Défaut ou panne d'organes de commande,
 - Défaut ou panne de processus,
 - Défaut ou panne de l'unité de traitement ou de commande.
- **Signe**, un défaut est perceptible au travers d'un signe, caractère manifestant un état comportemental anormal. Un signe est caractérisé par un ensemble d'observations en provenance d'un système physique et est révélateur de la présence d'un défaut.
- **Symptôme**, le pendant de signe dans le cas d'une défaillance correspond au terme symptôme, définit comme suit : caractère distinctif d'un état fonctionnel anormal.

La distinction entre les termes symptôme et signe s'apparente donc à la différence entre notions de défaut et de défaillance. Un symptôme révélateur d'une défaillance est nécessairement un signe, alors qu'un défaut se manifeste au travers de signes qui ne sont pas nécessairement des symptômes.

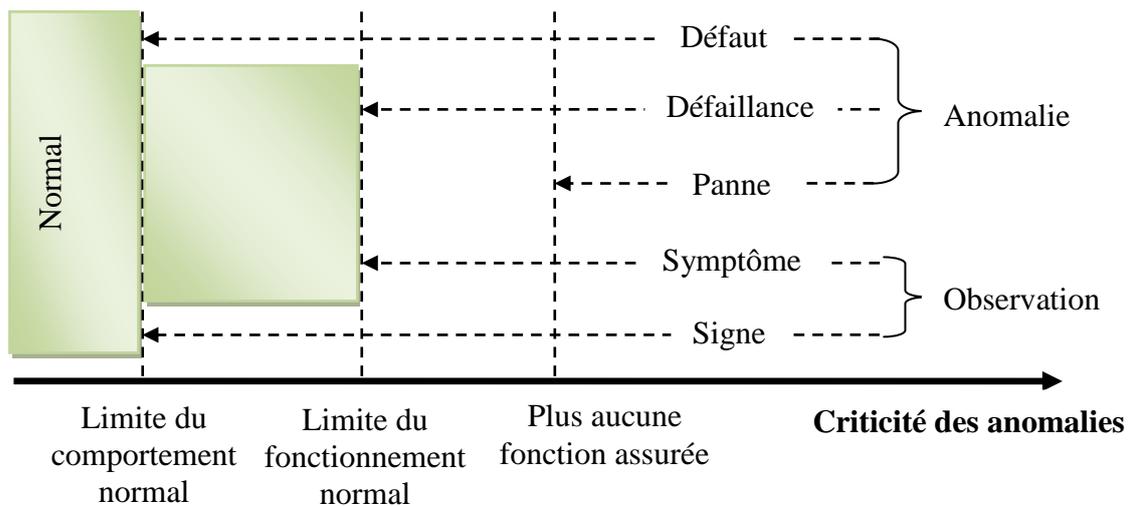


Figure 1.1. Ordonnement des anomalies selon leur criticité

- Un **Résidu**, communément appelé indicateur de défaut ou variable d'écart, est un signal conçu comme indicateur d'anomalies comportementales ou fonctionnelles.
- L'**incertitude** est le fait de ne pas connaître ou prévoir l'état de la réalité pour déterminer la valeur de vérité d'une proposition.
- L'**imprécision** fait référence à la description incomplète d'un état de la réalité par une proposition.

1.3. La supervision et le diagnostic

La supervision est définie comme étant la surveillance, le diagnostic et la décision, c.-à-d, elle consiste à gérer et à surveiller l'exécution d'une opération ou d'un travail accompli par l'homme ou par une machine, puis proposer des actions correctives si besoin est.

La supervision continue des systèmes industriels est nécessaire pour assurer des conditions d'opération pour lesquelles les algorithmes de commande sont efficaces.

Lorsque la fonction de surveillance est réalisée par un opérateur humain, viennent s'ajouter au problème du choix des méthodes et architecture de cette fonction, des concepts liés à l'ergonomie des systèmes développés. Il est apparu entre autre, que les défauts les plus difficiles à détecter sont les défauts qui s'installent lentement, sous forme de dérives, car on peut mettre un certain temps à voir leurs effets apparaître clairement.

Les méthodes avancées de diagnostic de défauts sont nécessaires, pour répondre aux exigences comme l'anticipation de la détection de défauts avec variations brutales du comportement, le diagnostic de fautes d'actionneur, de comportement du système et du

capteur, la détection de défauts dans les boucles fermées et la supervision des systèmes lors d'états transitoires. L'objectif de l'anticipation de la détection de défauts et du diagnostic est d'avoir assez de temps pour traiter des actions, comme la reconfiguration du système ou la maintenance.

Selon [NOU 05], la supervision nécessite la mise en œuvre de nombreuses tâches décrites par la Figure 1.2.

Ces différentes tâches sont détaillées dans ce qui suit:

- L'extraction des informations nécessaires à la mise en forme des caractéristiques associées aux fonctionnements normaux et anormaux, à partir des moyens de mesures appropriées ou d'observations réalisées hors des rondes par les personnels de surveillance.
- La caractérisation des défauts est l'élaboration des caractéristiques et signatures associées à des symptômes révélateurs de défaillances et de dégradations en vue de la détection d'un dysfonctionnement.
- La détection de défauts permet de déterminer si le système physique fonctionne normalement et a pour objectif de signaler la présence d'un défaut en comparant le comportement courant du système avec celui donné pour référence.
- L'opération de localisation qui suit l'étape de détection a pour objet la localisation d'un défaut détecté survenant sur les actionneurs, les capteurs d'instrumentation, la commande ou le système commandé en indiquant quel organe ou composant est affecté par celui-ci.
- La tâche d'identification a pour but de caractériser le défaut en durée et en amplitude afin de le classer par types et degrés de sévérité. Ainsi, il peut servir à assurer le suivi de son évolution, ce qui est fort utile dans le cas d'un changement de comportement lent dû au vieillissement et à l'usure. De plus, cette tâche peut comprendre une procédure visant à déterminer la cause du défaut, c'est-à-dire son origine.

Ces trois dernières tâches constituent le corps d'une procédure de diagnostic. Lorsqu'une anomalie est détectée, le module de diagnostic doit donc :

- vérifier que celle-ci est bien un défaut,
- puis, localiser le défaut pour déterminer le composant incriminé,
- enfin, identifier le défaut, c'est-à-dire déterminer ses caractéristiques.

- La prise de décision en fonction des conséquences futures des défaillances et des dégradations. Cette prise de décision peut conduire à un arrêt de l'installation si ces conséquences sont importantes.

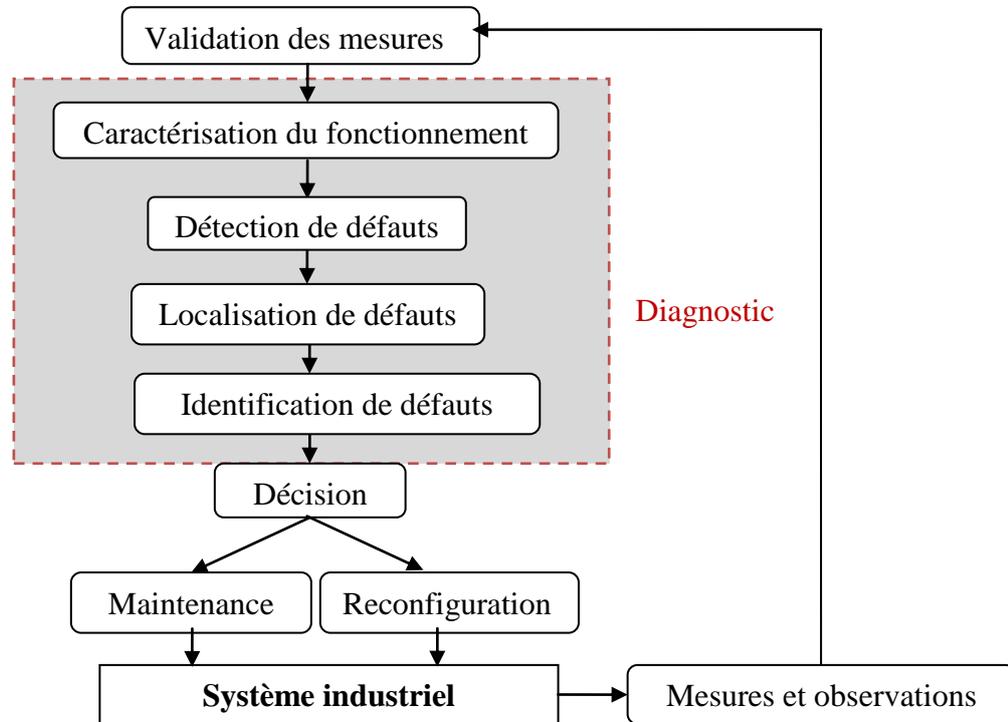


Figure.1.2. Les différentes étapes de la supervision

1.4. Les différentes méthodes de diagnostic

De nombreuses méthodes sont à la base des travaux en diagnostic, le choix de l'une de ces méthodes est lié à la connaissance que l'on souhaite acquérir sur le système, mais aussi à la complexité de ce système. En effet deux grandes familles peuvent être prises en considération: les méthodes à base de modèles et les méthodes sans modèles appelées aussi les méthodes à base de signal comme montre la figure1.3. La première famille repose sur une connaissance en profondeur du système incluant les relations causales entre les différents éléments tandis que la deuxième sur la connaissance glanée à partir d'expériences passées (on parlera aussi de connaissance superficielle, apparente basée sur l'histoire du processus) [HER 06]. Nous décrivons ci-dessous quelques principales méthodes de ces deux familles.

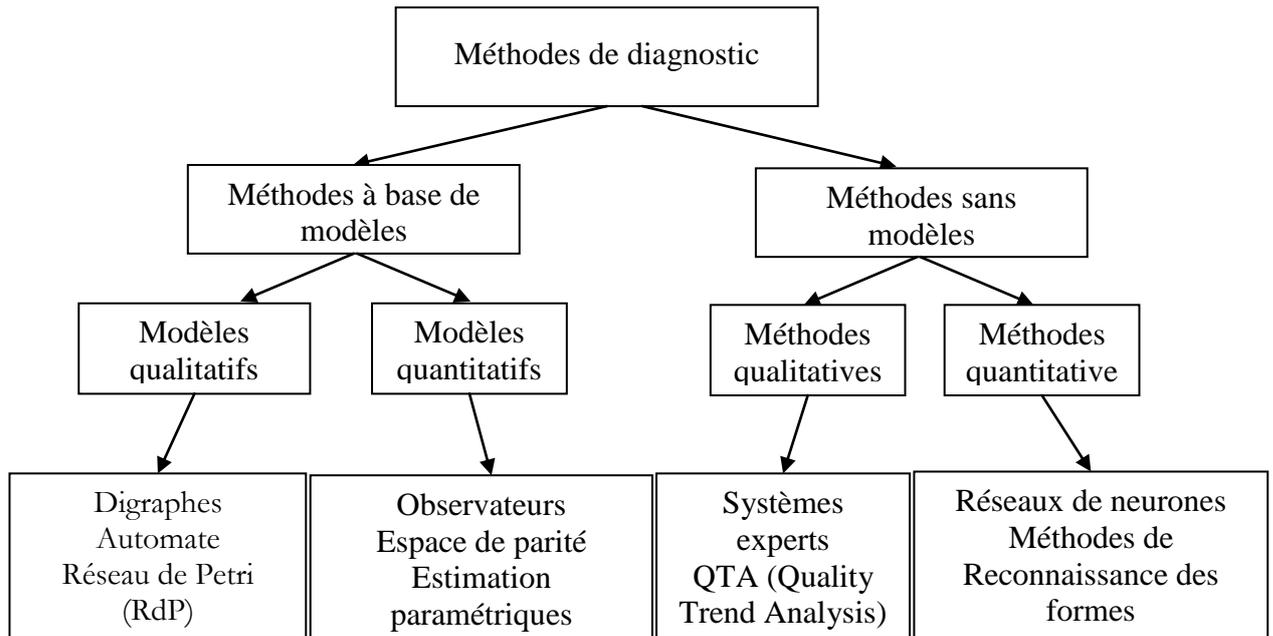


Figure 1.3. Classification des méthodes de diagnostic

1.4.1. Méthodes à base de modèles

Ces méthodes reposent sur une connaissance physique profonde du système à diagnostiquer. La méthode de diagnostic s'appuie sur la comparaison du comportement réel observé sur le système physique avec le comportement prédit à l'aide de modèles de son comportement nominal. La détection d'incohérences permet de conclure sur l'occurrence de faute dans le système. Un modèle de dysfonctionnement (modèle de faute) permet de localiser les fautes et éventuellement de les identifier.

Deux principales approches peuvent se distinguer dans les méthodes de diagnostic à base de modèles: les méthodes quantitatives FDI (Fault Detection and Isolation) issues de la communauté automatique et les méthodes qualitatives issues des communautés de l'intelligence artificielle (IA) et des systèmes à événements discrets (SED).

1.4.1.1. Méthodes à base de modèles qualitatifs

Les modèles qualitatifs permettent d'abstraire le comportement du procédé avec un certain degré d'abstraction à travers des modèles non plus mathématiques mais des modèles de type symbolique. Contrairement aux modèles de type numérique, les modèles qualitatifs ne représentent pas la physique du système, mais ils le décrivent en terme de mode de fonctionnement [DER 09]. Divers modèles de représentation qualitative des systèmes continus, discrets et hybrides ont été utilisés dans le cadre de diagnostic. Parmi les méthodes les plus populaires, citons les graphes causaux pour les systèmes continus, les

automates d'états finis et les réseaux de Petri pour les systèmes discrets et les automates hybrides [DER 09], les bond graphs et réseaux de Petri hybrides pour les systèmes hybrides [MOK 07].

Une limitation importante de ces méthodes réside dans la génération d'un grand nombre d'hypothèses pouvant conduire à une résolution erronée du problème ou à une solution très incertaine.

1.4.1.2. Méthodes à base de modèles quantitatifs

Le principe de diagnostic à base de modèles quantitatifs consiste à comparer le comportement réel du système tel qu'il peut être observé par l'intermédiaire de capteurs et son comportement attendu tel qu'il peut être prédit grâce aux modèles de bon fonctionnement. Toute contradiction entre les observations et les prédictions déduites des modèles, autrement résidu ou indicateur de défaut, permet de révéler la présence d'un ou plusieurs défauts, comme illustré sur la figure 1.4. Les techniques de génération de résidus seront différentes. Trois approches sont particulièrement utilisées pour la génération des résidus [COC 04]:

- L'approche d'estimation paramétrique: qui consiste à identifier en ligne les divers paramètres du système et à comparer ses estimations aux valeurs nominales des paramètres. L'erreur d'estimation est utilisée comme résidu. Le lecteur intéressé par cette approche pourra consulter par exemple le travail de [BAC 02].
- L'approche de l'espace de parité: son principe est de transformer, réécrire les équations du modèle de manière à obtenir des relations particulières appelées RRA: Relations de Redondance Analytique. Ces relations ont pour propriété de ne lier que des grandeurs connues, disponibles en ligne. Les résidus sont obtenus en substituant dans ces RRA les variables connues par leurs valeurs réelles, prélevées sur le système en fonctionnement. L'obtention hors-ligne des RRA est un problème général d'élimination de variables dans un système d'équations algèbro-différentielles. Lorsque le modèle est linéaire, l'élimination peut se faire par projection dans un sous espace appelé espace de parité.
- L'approche à base d'observateurs ou de filtres: son principe général est de concevoir un système dynamique permettant de donner une image, ou estimation, de certaines variables, ou combinaisons de variables, nécessaires au bouclage. Ces outils ont été adaptés à des fins de diagnostic et les travaux utilisant ces approches sont nombreux, on peut citer [BOU 01] [NAI 00]. L'écart entre les fonctions de sorties estimées et les mêmes fonctions des sorties mesurées est utilisé comme résidu.

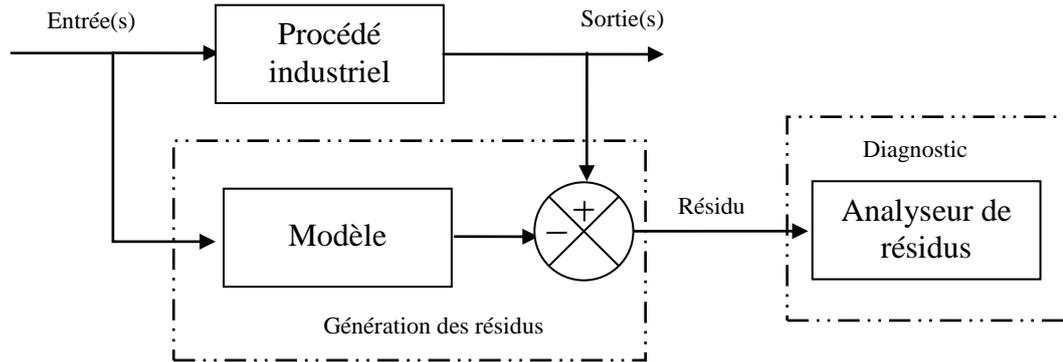


Figure 1.4. Principe de diagnostic basé sur la génération des résidus.

Une fois les résidus générés, la deuxième étape consiste à les exploiter dans le cadre du diagnostic pour décider la présence ou non d'un défaut dans le système. Les méthodes de détection sont regroupées sous le terme de test de cohérence, leur objectif est de vérifier l'adéquation entre les grandeurs observées, et les résidus issus du modèle, décrivant le comportement attendu du système. L'un des tests les plus simples consiste à comparer les résidus à des seuils fixes. Le choix de ces seuils est délicat, car il demande généralement de faire un compromis: si le seuil est trop bas, on risque d'augmenter le nombre de fausses alarmes, mais s'il est trop élevé, ce sont les non détections qui vont se multiplier. Il existe également d'autres tests plus robustes, comme le test de la somme cumulée, ou le test du maximum de vraisemblance généralisé.

Lorsqu'une défaillance est détectée, une procédure de localisation et d'identification est utilisée pour permettre de déterminer son origine et ces caractéristiques précises. Ces deux étapes nécessitent d'utiliser les modèles de dysfonctionnement.

Dans le paragraphe suivant, nous allons voir d'autres méthodes de diagnostic dites sans modèle qu'on appelle méthodes à base de signal, capables de décider l'état de fonctionnement des processus à partir juste des signaux de sortie (sans passer par le calcul des RRA).

1.4.2. Méthodes sans modèle

Dans certaines applications industrielles, il est difficile, voire impossible, d'obtenir le modèle du système. Cette difficulté est justifiée par la complexité du système. En effet, seules les méthodes de diagnostic sans modèles sont opérationnelles pour ce type d'applications industrielles. Ces méthodes de diagnostic se basent sur des informations issues d'une expérience préalable ou sur des règles heuristiques.

Dans cette partie, nous allons présenter quelques unes de ces techniques ainsi que leur application dans le domaine du diagnostic des systèmes industriels.

1.4.2.1. Méthodes Qualitatives

- **Systèmes expert**

Un système expert (SE) est un logiciel destiné à assister l'homme en incorporant la connaissance et l'expérience des spécialistes [BRU 90]. En d'autres termes le but de reproduire le raisonnement qui conduit un expert humain à prendre une décision sur l'état du système à partir d'observations de celui-ci, données sous forme symbolique.

L'architecture générale d'un système expert se comporte principalement de trois éléments (figure 1.5): une base de connaissance, un moteur d'inférence et des interfaces utilisateurs.

- La base de connaissance se compose généralement de deux parties: la base de faits et la base de règles. La base de faits (BF) regroupe toutes les observations faites sur le système à diagnostiquer. La base de règles (BR) contient les connaissances opératoires représentant le "savoir-faire" sur le domaine étudié.
- Moteur d'inférence: C'est le programme qui combine les faits, déclenche les règles applicables et génère de nouveaux faits. Le moteur répète le cycle suivant: sélection des règles, filtrage des règles, résolution des conflits et enfin exécution.
- Interfaces utilisateurs: Les interfaces utilisateurs permettent aux opérateurs de consulter le système expert. Ils peuvent ainsi vérifier et éventuellement mettre à jour leurs connaissances.

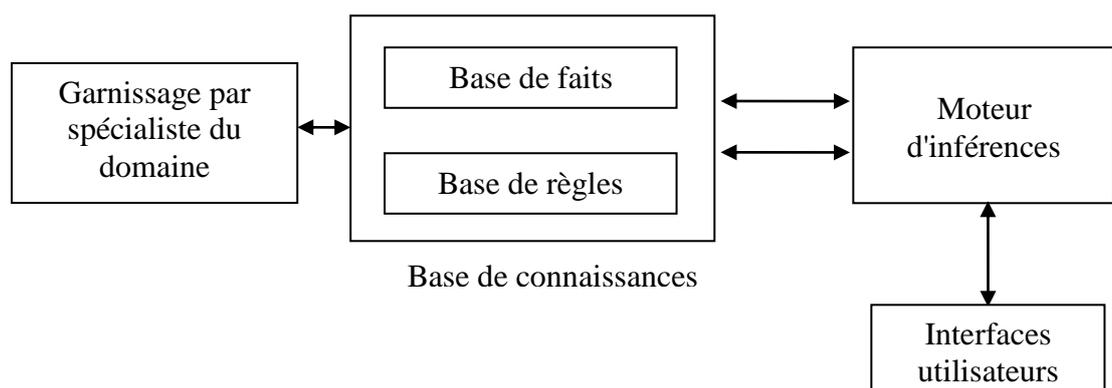


Figure 1.5. Structure d'un système expert

En diagnostic, ce type d'approche est adapté aux problèmes nécessitant la manipulation d'une quantité importante de données non homogènes. Ils ont beaucoup été utilisés dans le

diagnostic des systèmes statiques. Pour des systèmes dynamiques, ce type d'approche est peu adapté pour des problèmes de temps-réel et de gestion dynamique de l'information.

- **Analyse de tendance qualitative (QTA)**

L'analyse de tendance qualitative utilise l'information de type tendance présente dans les mesures issues des capteurs. Il y a deux étapes de base, l'identification de tendances dans les mesures, et l'interprétation de ces tendances en terme de scénarios de fautes. Le processus d'identification doit être robuste par rapport aux variations momentanées du signal (dues au bruit) et capturer seulement les variations importantes. Le filtrage peut altérer le caractère qualitatif essentiel contenu dans le signal. Ces tendances dans le processus peuvent être transformées en fautes pour ainsi construire la base de connaissance utilisée pour le diagnostic [HER 06].

[ROC, 06] énumère les besoins des systèmes de supervision qui motivent l'utilisation des méthodes d'analyse qualitative de tendances :

- L'incertitude, l'incomplétude et l'hétérogénéité (différentes échelles de temps par exemple) des données demandent un raisonnement qualitatif.
- Un raisonnement temporel est nécessaire non seulement sur des informations instantanées mais aussi sur le comportement historique.
- Face au volume de données présent dans les procédés complexes, il est souhaitable une représentation symbolique et adaptée au système de surveillance.
- La représentation de la connaissance doit être adaptée à l'interprétation de l'opérateur humain.

1.4.2.2. Méthodes quantitatives

Les méthodes quantitatives consistent en l'exploitation des observations quantitatives, la seule information disponible, sous la forme de données historiques ou de traitement en ligne des signaux issus de capteurs. Parmi ces méthodes, on trouve:

- **Réseaux de neurones artificiels**

Les réseaux de neurones sont des outils d'analyse statistique permettant de construire un modèle de comportement à partir d'un certain nombre de variables descriptives de ce comportement.

Un réseau de neurones artificiels (RNA) se compose typiquement d'une couche d'entrée, d'une ou plusieurs couches intermédiaires ou couchées et d'une couche de sortie. Dans le

fonctionnement du RNA, chaque nœud ou neurone est connecté à d'autres neurones d'une couche suivante par des poids synaptiques adaptables [KEM 04].

La figure 1.6 montre le schéma général d'un neurone formel. Les entrées du neurone sont désignées par x_i ($i=1,\dots,n$). Les paramètres w_i reliant les entrées aux neurones sont appelés poids synaptiques ou tout simplement poids. La sortie y du neurone est donnée par:

$$y=f(u) \text{ avec } u=\sum_{i=1}^n w_i x_i$$

où:

u est l'état d'activation du neurone (également appelé état interne du neurone).

f est la fonction d'activation du neurone. La figure 1.7 représente les fonctions d'activation les plus utilisées.

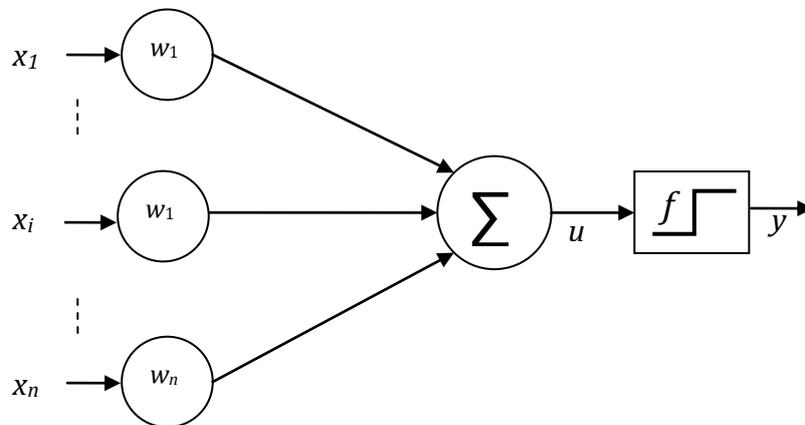


Figure 1.6. Schéma général d'un neurone

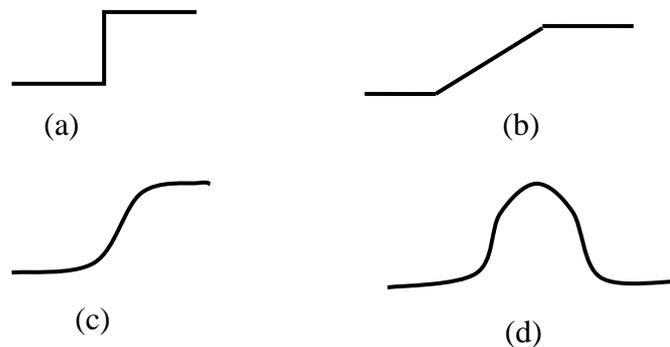


Figure 1.7. Fonctions d'activation les plus utilisées: (a) fonction à seuil, (b) fonction linéaire, (c) fonction sigmoïde, (d) fonction gaussienne [KEM 04]

Cette technologie comporte des caractéristiques très intéressantes comme la faculté d'apprentissage et d'auto-organisation. Elle présente des perspectives d'applications particulièrement intéressantes pour l'aide au diagnostic. Pour identifier des défauts dans un système, le diagnostic réalisé par réseaux de neurones doit disposer d'un nombre suffisant d'exemples de bon fonctionnement et de défauts pour pouvoir les apprendre. Pendant la phase d'apprentissage, les exemples sont présentés au réseau en entrée avec les diagnostics correspondants à la sortie. Le réseau s'auto-organise, apprenant à relier les exemples montrés aux diagnostics. Après l'apprentissage, le réseau ne reconnaît pas seulement les exemples appris mais également des paradigmes leur ressemblant, ce qui correspond à une certaine robustesse par rapport aux déformations de signaux par le bruit.

Pour un traitement par réseau de neurones, les exemples doivent être mis en forme pour être entrés dans le réseau. Ce sont des grandeurs caractéristiques des défauts à diagnostiquer, filtrées et prétraitées (transformée de Fourier).

Conceptuellement, un réseau de neurones peut être considéré comme une boîte noire, il n'est pas nécessaire de construire un modèle du système, contrairement aux méthodes à base de modèles.

Cependant, l'inconvénient majeur est d'arriver à déterminer une méthodologie pour maîtriser les problèmes inhérents, qui sont principalement le choix de la structure, de la taille du réseau et des algorithmes d'apprentissage pour un problème précis. Par contre, la principale raison de leur intérêt en diagnostic industriel est leur faculté d'apprentissage et la mémorisation d'un grand volume d'information.

- **La reconnaissance des formes (RdF)**

La reconnaissance des formes regroupe l'ensemble des méthodes permettant de classer des objets ou des formes en les comparant à des formes types. Ses applications interviennent dans de nombreux domaines tels que la reconnaissance vocale, la reconnaissance de caractères et de mots, détection de fraudes dans les réseaux téléphoniques, diagnostic médical. Il existe plusieurs approches en reconnaissance de formes : la reconnaissance des formes structurelles ou syntaxiques [DEN 02], [MIC 84], qui se base sur une représentation des formes à l'aide de grammaires et la reconnaissance des formes numériques de type statistique [DUB 01], floue [DEN 01],...

Lorsque les observations sont de types numériques et qu'on ne peut pas construire de modèle mathématique correspondant aux divers modes de fonctionnement du système ou si sa complexité le rend inexploitable, les méthodes basées sur la RdF sont les plus

adaptées. De nombreux travaux [LER 90], [SAI 01], [ARR 02], [RAG 03] ont permis de montrer l'intérêt de ce type d'approche.

Le diagnostic par RdF se représente comme une solution alternative à l'approche par modèle puisque les modes de fonctionnement sont modélisés, pas de manière analytique, mais en utilisant uniquement des mesures de ces modes [ALA 04]. L'objectif de la reconnaissance des formes, illustré sur la figure 1.8, est alors de savoir associer toute nouvelle observation à une classe de l'espace de décision correspondant à un mode de fonctionnement. L'affectation d'une observation X à l'une des M classes notées *classe 1*, *classe 2*, ..., *classe M* indique une opération de classement ou de discrimination.

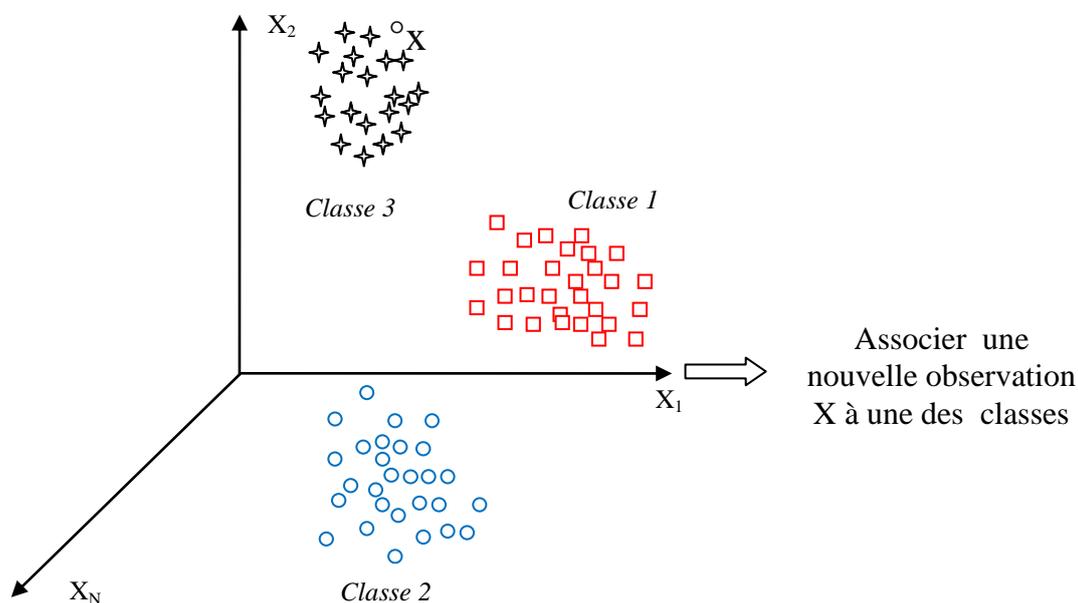


Figure 1.8. Principe de la reconnaissance des formes

Dans le domaine du diagnostic des systèmes industriels, la RdF numérique est la plus utilisée, elle a été mise en œuvre avec succès par [DEB 01], [CAS 03], [OND 06]. D'autres études ont utilisé l'association de la RdF et la théorie des ensembles flous pour détecter la transition entre les modes de fonctionnement normal et anormal [MOU 02].

Dans le chapitre suivant, nous allons montrer comment la RdF peut servir de base à la conception d'un système de diagnostic, et l'avantage essentiel qu'elle présente par rapport aux autres approches. Cette méthode procure au système de diagnostic des moyens d'appréhender la connaissance a priori incomplète des modes de fonctionnement du processus et ainsi, permettre la mise en place d'une méthode de diagnostic évolutive.

1.4. Conclusion

À travers ce premier chapitre, nous avons essayé de faire un rappel de la terminologie utilisée dans le domaine de diagnostic de défaillances des systèmes industriels avec un exposé sommaire sur les différentes méthodes de diagnostic s'y rapportant. Si le comportement de système est parfaitement connu, les modèles utilisés peuvent fournir une estimation fiable des grandeurs difficilement mesurables. Les signaux et paramètres de sortie sont alors utilisés pour la surveillance et le diagnostic. Toutefois, pour les systèmes industriels présentant des difficultés liées à l'obtention de modèle reproduisant fidèlement leur comportement, d'autres méthodes de diagnostic sont utilisées. L'une de ces méthodes dites sans modèle est la reconnaissance des formes qui sera détaillée dans le chapitre suivant. Nous focalisons notre étude sur les approches de reconnaissance des formes floue.

Méthodes de reconnaissance des formes floue

Chapitre 2:

Méthodes de reconnaissance des formes floue

2.1. Introduction

Dans la pratique, beaucoup de systèmes industriels ne disposent pas d'un modèle de comportement. On relève simplement les observations correspondant aux différents modes de fonctionnement du système. La méthode de reconnaissance des formes floue se trouve adaptée à ce genre de situations.

Dans ce chapitre, nous essayerons d'exposer la formulation générale se rapportant à la méthode RdF floue et de détailler les différentes étapes nécessaires à la conception du diagnostic d'un système industriel par cette méthode sous ses différentes variantes.

2.2. Procédure de diagnostic par reconnaissance des formes

Le principe de RdF repose sur la représentation numérique des observations, en supposant que chaque observation est caractérisée par un ensemble de d paramètres, est représentable par un vecteur X dans l'espace R^d . Le diagnostic par RdF [DUB 01] est posé formellement comme suit:

- Définir les paramètres constituant le vecteur formes X à partir du traitement des mesures effectuées sur le système,
- Déterminer les différentes classes correspondant aux différents modes de fonctionnement,
- Construire une règle de décision qui décide d'affecter ou non une nouvelle observation à une classe.

Ces différentes étapes sont illustrées par la figure suivante:

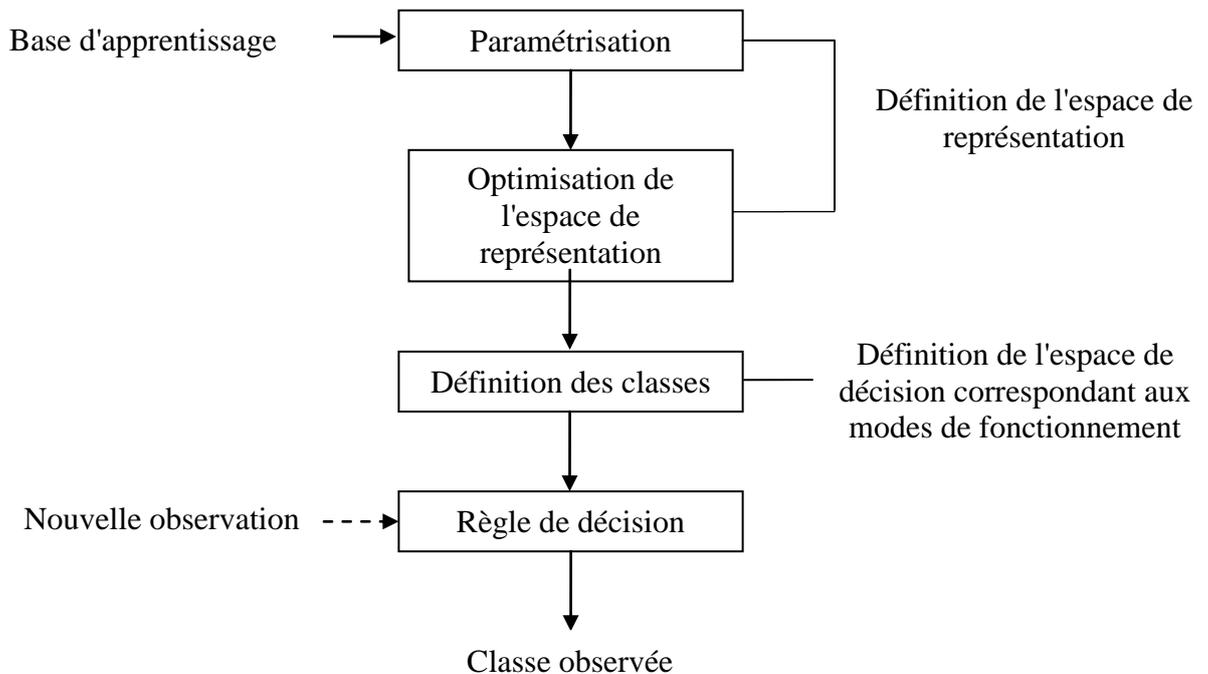


Figure 2.1. Les étapes d'une procédure de la reconnaissance des formes

2.2.1. Détermination de l'espace de représentation

La première étape consiste à traiter les différentes mesures effectuées sur le système à diagnostiquer. Ces mesures peuvent être sous forme de signaux, donc il est nécessaire d'extraire des données numériques, en utilisant les méthodes de traitement de signaux.

L'ensemble de d paramètres obtenus est représenté par un vecteur appelé *vecteur forme* X_f qui sera représenté par un point dans l'espace de représentation R^d .

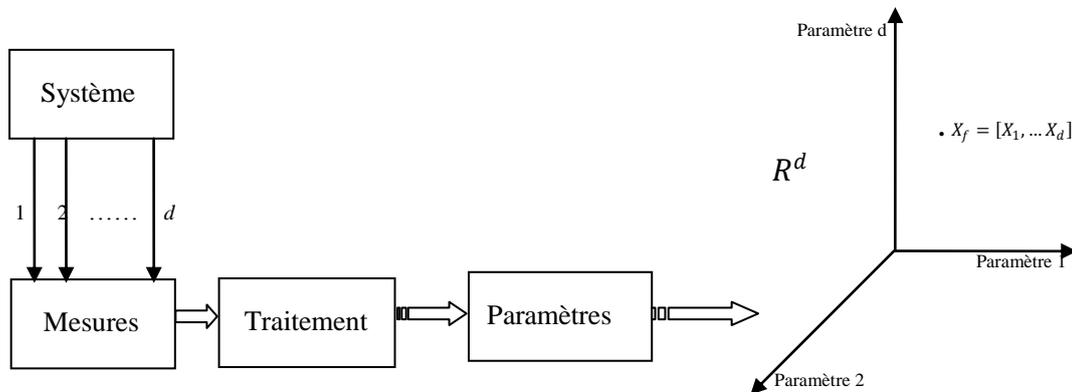


Figure 2.2. Cheminement pour la détermination de l'espace de représentation

Les performances du système de diagnostic dépendront de la pertinence des paramètres calculés. Il est donc préférable de disposer de paramètres variant, de manière significative, en fonction des différents modes de fonctionnement du système. Les N observations (ou vecteurs: (X_1, X_2, \dots, X_N) recueillies sur le système constituent l'ensemble d'apprentissage.

Le nombre souvent élevé de paramètres peut être pénalisant en terme de temps de calcul. De plus les paramètres obtenus ne sont pas tous pertinents ou significatifs pour la tâche à réaliser, donc il est nécessaire de définir un nouvel espace de représentation de dimension réduite, afin de ne conserver que les variables les plus pertinentes.

2.2.1.1. Réduction de l'espace de représentation

La définition de nouvel espace de représentation de dimension réduite consiste à rechercher un sous-ensemble de d' paramètres ($d' < d$), qui conserve le mieux possible la séparation des classes de l'ensemble d'apprentissage initial. La réduction de l'espace de représentation permet de diminuer le temps de classification pour toute nouvelle observation et d'éviter la dégradation des performances de la règle de décision. Cette réduction de l'espace de représentation peut être réalisée par les méthodes d'extraction de variables ou par les méthodes de sélection de variables.

2.2.1.1.1. Extraction de variables

L'extraction de variables consiste à définir de nouveaux paramètres ($d' < d$) en fonction des variables initiaux. Les méthodes de l'extraction de variables ne permettent pas

de réduire le nombre de variables à traiter pour chaque observation, les nouveaux paramètres sont des combinaisons linéaires des paramètres initiaux.

Parmi les méthodes de l'extraction de variables, nous pouvons citer l'analyse en composantes principales (ACP) [THA 08], la régression aux moindres carrés partiels (PLS) [OUK 04], les cartes de Kohonen,

-Analyse en composantes principales (ACP)

Soit $X_a = (X_1, X_2, \dots, X_N)$ l'ensemble d'apprentissage composé de N vecteurs de dimension d . L'Analyse en Composantes Principales est une méthode permettant d'identifier un sous espace $R^{d'}$ de dimension $d' < d$ représentant au mieux l'ensemble X_a . On notera u_j , la base orthogonale de dimension d' représentant cet espace. Les vecteurs u_j avec $j = 1, \dots, d'$ sont appelés axes factoriels ou axes principaux.

Pour déterminer la nouvelle base, deux approches équivalentes mais exprimées différemment sont proposées pour traduire le critère de représentation optimale de l'ensemble (X_1, X_2, \dots, X_N) :

- Minimisation de la déformation du nuage de points projetés dans la nouvelle base, qui conduit à minimiser:

$$J = \frac{1}{2} \sum_{i=1}^N d^2(X_i, X_i^p) \quad (2.1)$$

avec,

$d(.,.)$ est une mesure de distance,

N le nombre de vecteurs dans l'ensemble d'apprentissage,

X_i^p la projection du vecteur X_i dans la base formée par les u_j .

- Maximisation de la variance des points projetés sur chaque axe factoriel:

$$J' = u_j^t [\sum_{i=1}^N (X_i - \bar{X})(X_i - \bar{X})^t] u_j = u_j^t \Sigma u_j \quad (2.2)$$

avec, Σ est la matrice de variance-covariance:

$$\Sigma = \frac{1}{N} \sum_{i=1}^N (X_i \cdot X_i^t) - \bar{X} \cdot \bar{X}^t \quad (2.3)$$

\bar{X} : centre de gravité de l'ensemble d'apprentissage:

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (2.4)$$

Dans les deux cas, les vecteurs u_j sont les vecteurs propres de la matrice de variance-covariance, classés selon l'ordre des valeurs propres décroissantes.

Si les variables ne sont pas homogènes, c'est-à-dire si l'une d'entre elle présente des valeurs beaucoup plus grandes que les autres, alors l'influence de cette variable sera prépondérante dans le calcul de la matrice Σ et donc sur les résultats de l'ACP. Il est alors nécessaire de normaliser les variables par leurs variances en introduisant la matrice diagonale Δ des variances σ_j^2 :

$$\Delta = \begin{bmatrix} 1/\sigma_1^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 1/\sigma_d^2 \end{bmatrix} \quad \text{où} \quad \sigma_j^2 = \frac{1}{N} \sum_{i=1}^N (X_{ij} - \bar{X}_j)^2 \quad (2.5)$$

avec,

$$j = 1 \text{ à } d$$

X_{ij} : la $j^{\text{ième}}$ composante de X_i

\bar{X}_j : la moyenne de la composante j

Ainsi, à partir des deux relations précédentes on en déduit les vecteurs formes normalisés (c'est-à-dire de moyenne nulle et d'écart type unité):

$$X_{i \text{ norm}} = \Delta^{1/2} (X_i - \bar{X}) \quad (2.6)$$

Pour la suite de l'étude, les données seront considérées comme étant centrées-réduites (c'est -à-dire de moyenne nulle et d'écart type unité).

Les résultats de l'ACP peuvent être visualisés en considérant la projection du nuage de point sur les deux ou trois premiers axes factoriels. Autrement dit, en visualisant la matrice des données dans l'espace défini par les deux ou trois premiers vecteurs propres.

Enfin la qualité de la représentation peut être quantifiée par le calcul du pourcentage d'inertie expliqué sur chaque axe factoriel ou sur le sous-espace de dimension d obtenu. Ce pourcentage d'inertie est défini en fonction des valeurs propres.

Soit $(\lambda_1, \dots, \lambda_{d'})$, les d' valeurs propres obtenues classées par ordre décroissant, le pourcentage d'inertie expliqué par un axe i est donné par :

$$\Gamma_i = \frac{\lambda_i}{\sum_{j=1}^d \lambda_j} \quad (2.7)$$

et la qualité de la représentation du nuage de points s'exprime:

$$\Gamma = \frac{\sum_{i=1}^{d'} \lambda_i}{\sum_{j=1}^d \lambda_j} \quad (2.8)$$

Plus ce dernier rapport est proche de 1, meilleure est la représentation. En pratique, l'utilisateur fixe le seuil de qualité (80%, 90%) puis sélectionne séquentiellement les vecteurs u_j lui permettant d'atteindre ce seuil afin de définir la base du sous-espace.

2.2.1.1.2. Sélection de variables

La sélection de variables consiste à sélectionner les d' variables les plus pertinentes parmi les d variables initiales, conservant au mieux l'information sur la structure des classes, donc elle permet de réduire le nombre de paramètres à traiter et de faciliter l'apprentissage. Ces méthodes supposent que le nombre de classes est connu ainsi que les observations correspondantes.

Une méthode de sélection de variables est composée généralement des composantes suivantes [LER 98]:

- un critère de qualité pour quantifier la qualité d'un paramètre,
- une procédure de recherche, pour explorer l'espace des différentes combinaisons de variables,
- un critère d'arrêt, pour stopper la procédure de recherche ou déterminer l'ensemble de variables à sélectionner.

❖ Critère de qualité

Le critère utilisé pour la détermination du sous-espace E' , doit représenter au mieux les classes supposées connues de X_a , ce qui correspond intuitivement à :

- _ un regroupement des points d'une même classe, c'est-à-dire à une minimisation de la variance intra-classe.
- _ une séparation des différentes classes, soit une maximisation de la variance inter-classe.

Les matrices de variance intra-classe et inter-classe traduisent ces deux conditions. En effet l'expression de la matrice de variance intra-classe fait intervenir des échantillons de chaque classe ainsi que les centres de gravités:

$$\Sigma_W = \frac{1}{N} \sum_{k=1}^M \sum_{j=1}^{N_k} (X_{kj} - \bar{X}_k) (X_{kj} - \bar{X}_k)^t \quad (2.9)$$

Lorsque la matrice de dispersion inter-classe s'exprime en fonction des centres de gravité des classes et du centre de gravité de l'ensemble d'apprentissage:

$$\Sigma_B = \frac{1}{N} \sum_{k=1}^M (\bar{X}_k - \bar{X}) (\bar{X}_k - \bar{X})^t \quad (2.10)$$

avec,

M : nombre de classes

N : nombre de vecteur de l'ensemble d'apprentissage

N_k : nombre de vecteurs dans la classe ω_k

\bar{X}_k : centre de gravité de la classe ω_k

\bar{X} : centre de gravité de l'ensemble d'apprentissage

X_{kj} : $j^{\text{ième}}$ vecteur de la classe ω_k

On peut alors définir la matrice de variance-covariance par :

$$\Sigma = \Sigma_W + \Sigma_B \quad (2.11)$$

La matrice de variance-covariance traduit le fait que la dispersion totale est la somme de la dispersion à l'intérieur des classes et de la dispersion des classes entre elles.

Le critère de Fisher peut être appliqué comme critère, pour la sélection de paramètres. L'idée est de considérer successivement chacun des paramètres contenus dans le vecteur forme initial de dimension d et de calculer le critère pour ce paramètre.

Dans le cas de deux classes, le critère s'exprime, pour un paramètre α :

$$J(\alpha) = (\bar{X}_1(\alpha) - \bar{X}_2(\alpha)) / (N_1 \sigma_1^2(\alpha) - N_2 \sigma_2^2(\alpha)) \quad (2.12)$$

avec,

$\bar{X}_k(\alpha)$, ($k = 1, 2$), centre de gravité de la classe ω_k en ne considérant que le paramètre α .

$$\bar{X}_k(\alpha) = \frac{1}{N_k} \sum_{i_k}^{N_k} X_{i_k}(\alpha) \quad (2.13)$$

$\sigma_k^2(\alpha)$, ($k = 1, 2$), variance de la composante α des vecteurs de la classe ω_k

$$\sigma_k^2(\alpha) = \frac{1}{N_k} \sum_{j=1}^{N_k} [X_{kj}(\alpha) - \bar{X}_k(\alpha)]^2 \quad (2.14)$$

Dans le cas général d'un problème à M classes, $J(\alpha)$ s'exprime :

$$J(\alpha) = \sum_{k=1}^M \sum_{j=1}^{M-1} (\bar{X}_k(\alpha) - \bar{X}_j(\alpha)) / (N_k \sigma_k^2(\alpha) - N_j \sigma_j^2(\alpha)) \quad (2.15)$$

Le numérateur de l'expression (2.15) traduit la séparation des classes (variance inter – classes) alors que le dénominateur reflète la compacité des classes (par analogie avec la variance intra – classe). Plus le critère est grand, plus les classes sont séparées.

Si on considère les matrices de dispersion intra-classe et inter-classes (2.9) et (2.10), alors il est possible de définir deux autres critères, en utilisant les vecteurs propres de Σ_W^{-1} et Σ_B . Ces vecteurs sont invariants par une transformation linéaire non singulière. Ceci suppose $(N-M)$ et M supérieurs ou égaux à d . L'idée est donc d'utiliser les valeurs propres comme indicatrices du rapport de la dispersion entre classes et de la dispersion intra-classe:

$$J' = \text{trace}(\Sigma_W^{-1} \Sigma_B) \text{ et } J'' = \det(\Sigma) / \det(\Sigma_W) \quad (2.16)$$

L'expression J' a été utilisée comme critère dans les méthodes de sélection. Par la suite, il sera noté J .

❖ Procédure de recherche

Soit E l'espace composé de d paramètres initiaux, il est possible de rechercher un sous-espace E' de d' paramètres tel que:

$$J(E') = \max_{i=1, \dots, n_c} [J(E_{d'}^{(i)})] \quad (2.17)$$

avec,

n_c : le nombre de combinaisons (de d' paramètres parmi d) étudiées

$E_{d'}^{(i)}$: la $i^{\text{ième}}$ combinaison de d' paramètres pour laquelle on calcul la valeur de critère.

La première solution possible est de calculer le critère J sur toutes les combinaisons de d' paramètres possibles. C'est une technique exhaustive très lourde puisque le nombre de solutions à étudier est donné par :

$$C_d^{d'} = d! / ((d - d')! \cdot d'!) \quad (2.18)$$

Cette solution est vite dissuasive si la dimension de départ est élevée.

Il existe aussi des méthodes de sélection optimales telles que les algorithmes basés sur une procédure d'optimisation de type 'Branch and Bound'. Ces méthodes permettent de prendre en compte implicitement toutes les combinaisons de paramètres, sans devoir effectivement calculer le critère pour chaque combinaison. Pour cela, il faut faire l'hypothèse de monotonie du critère J , c'est-à-dire une diminution de J lorsque la dimension de l'espace décroît.

Il existe aussi des méthodes de sélection sous-optimales qui présentent l'avantage d'être rapide et de fournir des résultats réalistes. On peut citer entre autres :

- Méthode SFS (Sequential Forward Selection) effectue une sélection des paramètres de manière successive. L'idée est de partir d'un ensemble de variables vide et ajouter des variables à celles déjà sélectionnées.
- Méthode GSFS (Generalised Sequential Forward Selection) fonctionne comme l'algorithme précédent, mais cette fois-ci, plusieurs paramètres sont sélectionnés lors d'une itération.
- Méthode SBS (Sequential Backward Selection) qui comme son nom l'indique procède à l'inverse de la méthode SFS. Au départ, l'ensemble des paramètres sélectionnés est

initialisé comme l'ensemble des paramètres. A chaque étape, on élimine le paramètre pénalisant le plus le critère J .

- Méthode GSBS (Generalised Sequential Backward Selection) est la méthode symétrique de la méthode G.S.F.S. Elle utilise la même procédure que S.B.S. mais en éliminant plus d'un paramètre à chaque itération.

❖ Critère d'arrêt

Comme on pourra le voir par la suite, la classification d'une nouvelle observation, c'est-à-dire le diagnostic de l'état du système, dépend fortement de la sélection des paramètres de l'espace de représentation. Ainsi, la détermination de la dimension de l'espace est aussi un point clef, car sa valeur influence le résultat de la classification finale.

Une première solution consiste à regarder le résultat de la classification obtenu pour différentes valeurs de d' et de choisir la dimension pour laquelle le diagnostic est le meilleur. Mais cette solution nécessite l'intervention de l'utilisateur. L'idéal est de déterminer automatiquement et simultanément les meilleurs paramètres ainsi que la meilleure dimension. Pour cela, il suffit de suivre l'évolution du critère J utilisé en fonction des différentes valeurs de d' .

2.2.2. Structuration de l'espace de représentation

La structuration de l'espace de représentation consiste à chercher des régions, de l'espace de représentation, correspondant à chaque mode de fonctionnement. Cette étape fait appel à des techniques de classification, à partir de l'ensemble d'apprentissage. La classification peut être de deux natures, exclusive ou non. Le premier cas, lorsque toute observation appartient à une seule classe. En effet, chaque observation pourrait être munie d'un vecteur de fonctions d'appartenance caractérisant le degré d'appartenance de celle-ci à chacune des classes. Le second cas, lorsqu'une même observation peut appartenir à plusieurs classes. L'algorithme fournit alors une valeur numérique de l'appartenance de l'observation à chaque classe.

Lorsqu'on connaît la classe d'origine de chaque observation, l'espace de décision est parfaitement connu et l'apprentissage peut être effectué en mode supervisé, une telle approche permettrait d'établir directement une relation entre l'espace d'entrée et celui de sortie (c'est à dire entre les observations et les différentes classes ou modes de fonctionnement). Parmi ces méthodes [RAG 03] on peut citer les méthodes probabilistes, les K plus proches voisins, les réseaux de neurones à bas radiale, réseaux de neurones de type perceptron, les systèmes d'inférence floue et les machines à vecteurs supports.

Si au contraire on ne dispose d'aucune information sur la structuration de l'ensemble d'apprentissage en classes (c'est-à-dire on ne connaît pas les modes réels de fonctionnement des observations), l'apprentissage est dit non supervisé. Les méthodes de classification non supervisée, autrement appelées méthodes de coalescence, sont généralement intégrées dans des architectures plus complexes. La figure suivante présente ces différentes méthodes:

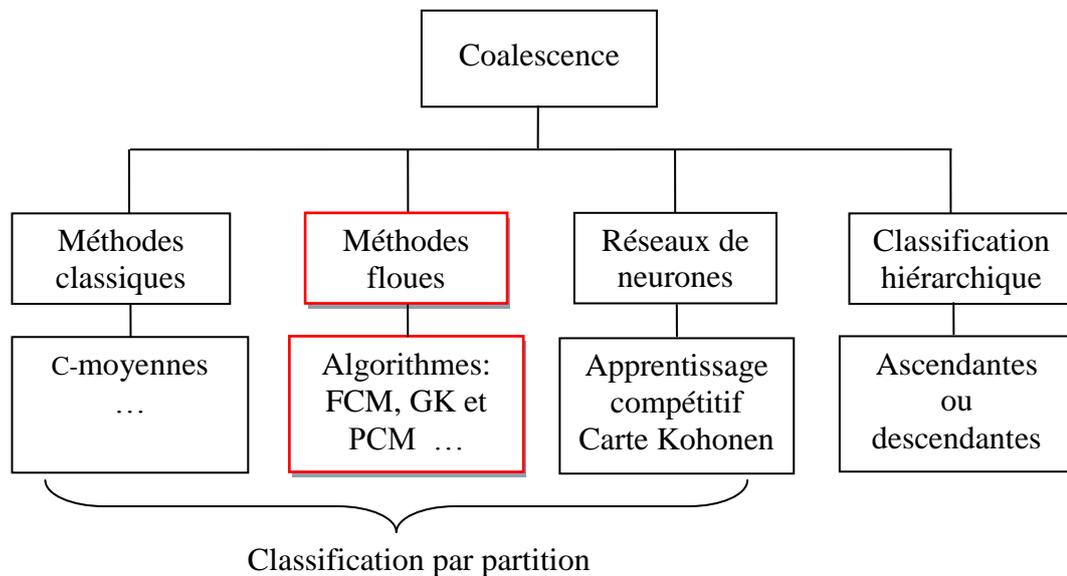


Figure 2.3. Les différentes méthodes de coalescence

2.2.3. Choix d'une méthode de décision

Les étapes précédentes ont permis de structurer l'ensemble d'apprentissage en classes distinctes et de pouvoir étiqueter les données de telle sorte que chacune des observations appartient à une des M classes connues.

Soit $X_a = (X_1, X_2, \dots, X_N)$ l'ensemble d'apprentissage et, $\{\omega_1, \dots, \omega_M\}$ l'ensemble des M classes (ou modes de fonctionnement en diagnostic) connues. Le problème posé est alors d'affecter une nouvelle observation X à l'une des M classes à l'aide d'une règle de décision.

Toutefois, l'affectation ne doit pas être systématique car des erreurs peuvent être commises. L'algorithme de décision doit donc bénéficier de solutions alternatives afin de diminuer le risque de mauvaise classification. Ces solutions sont fournies par les options de rejets d'ambiguïté et de distance. Il s'agit en réalité de différer la décision car les observations dont l'appartenance aux classes est ambiguë ou insuffisante, pourraient être précurseurs de l'apparition de nouvelles classes.

Le rejet d'ambiguïté est appliqué aux observations se situant à l'intersection de classes ou près d'une frontière entre deux classes comme le montre la figure 2.4.

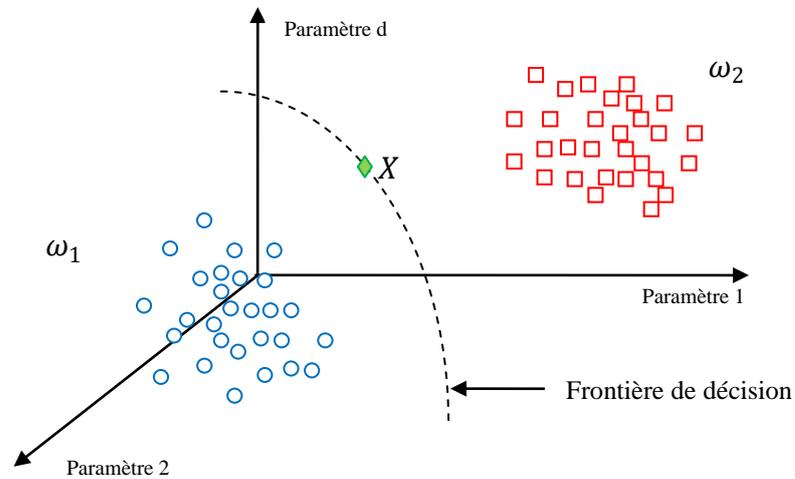


Figure 2.4. Rejet en ambiguïté

Les vecteurs se trouvant dans cette situation sont affectés à une nouvelle classe fictive ω_a appelée classe de rejet d'ambiguïté.

Le rejet de distance concerne les vecteurs situés dans des zones de l'espace qui ne correspondent à aucune des classes connues de l'ensemble d'apprentissage (Figure 2.5).

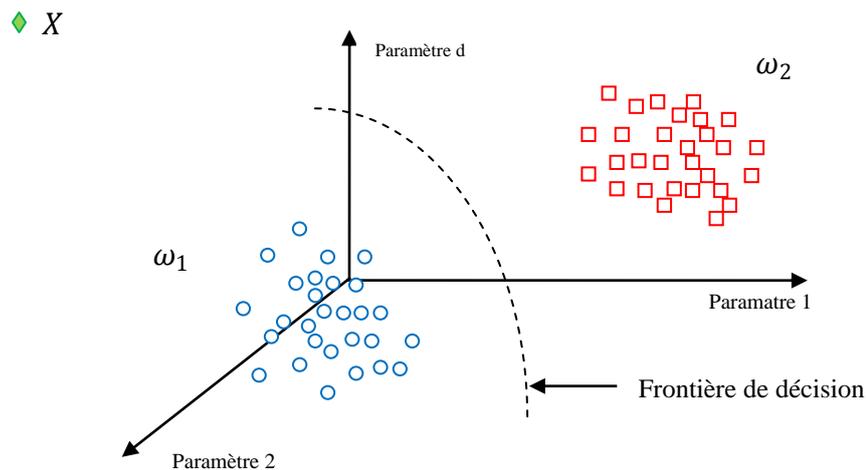


Figure 2.5. Rejet en distance

Cette autre alternative au risque de mauvaise classification est nécessaire en diagnostic. Ces nouvelles mesures peuvent laisser présager l'apparition de certains modes de fonctionnement qui étaient jusque là inconnus. Les vecteurs rejetés en distance seront affectés à une nouvelle classe fictive ω_d , appelée classe de rejet en distance.

La règle de décision peut être construite en utilisant une approche statistique ou une approche analytique. Dans le premier cas, on associe à chaque vecteur forme une densité de probabilité conditionnelle $f(X|\omega_j)$ par rapport à chaque classe ω_j . Dans le cas paramétrique, et si la connaissance est complète, la loi de cette densité est totalement connue, y compris ses paramètres. Si la connaissance sur $f(X|\omega_j)$ est incomplète mais si sa forme est connue, on estime ses paramètres.

Chaque classe ω_k est caractérisée par une probabilité a priori $p(\omega_k)$, ces probabilités vérifient la condition d'orthogonalité définie par :

$$\sum_{k=1}^M p(\omega_k) = 1 \quad (2.19)$$

Dans ce contexte, la règle de décision la plus couramment utilisée est la règle de bayes [DUB 90]:

$$X \rightarrow \omega_j \text{ si } p(\omega_j|X) = \max_{k=1,\dots,M} p(\omega_k|X) \quad (2.20)$$

Où $p(\omega_j|X)$ est la densité de probabilité a posteriori pour la forme X qui provienne de la classe ω_j , et elle est définie par la formule de Bayes:

$$p(\omega_j|X) = \left(f(X|\omega_j) \cdot p(\omega_j) \right) / \left(\sum_{k=1}^M f(X|\omega_k) \cdot p(\omega_k) \right) \quad (2.21)$$

La quantité au dénominateur est la densité de probabilité non conditionnelle de X appelée aussi densité de mélange $f(X)$.

Si la forme de $f(X|\omega_k)$ est inconnue, on utilise des méthodes non paramétriques, parmi les estimateurs usuels, on distingue les noyaux de Parzen et l'estimateur des K plus proches voisins (K-ppv) [DUB 01].

Il existe d'autres méthodes de classification qui divisent directement l'espace de représentation en des zones de décision en utilisant des indicateurs, des sorties binaires, telles que les réseaux de neurones basés sur la notion de distance ou les réseaux Learning Vector Quantization ou encore les classifieurs linéaires tels que les réseaux perceptron [MOU 02].

Dans l'approche analytique, une fonction discriminante est déterminée en estimant les paramètres d'une fonction mathématique, de manière à séparer au mieux les classes, c'est-à-dire à minimiser la probabilité de mauvaise classification. Le choix de la fonction mathématique dépend de la complexité de la frontière de décision. En pratique, on commence par des fonctions linéaires puis si la probabilité de mauvaise classification n'est pas satisfaite, on passe à des fonctions mathématiques plus complexes comme par exemple des fonctions quadratiques.

2.2.5. Exploitation du système de diagnostic

Une fois la règle de décision déterminée, l'étape suivante consiste à reconnaître à quel mode de fonctionnement correspond une nouvelle observation effectuée à un instant donné sur le système. Un problème peut survenir si cette observation ne peut être affectée à une classe (rejet en distance ou en ambiguïté). Dans ce cas il convient à interpréter ce rejet en termes de causes de ce changement de fonctionnement. Cela ne peut être que par un expert.

La méthode de diagnostic doit être adaptative, elle doit permettre de rechercher une nouvelle structure en classe pour les points rejetés, dès lors que leur nombre devient significatif. Un nouvel apprentissage est relancé afin de prendre en compte cette classe supplémentaire. La règle de décision est aussi à adapter.

La figure 2.6 représente une architecture d'un système de diagnostic adaptatif. A chaque présentation d'une nouvelle observation X , le module de décision affecte l'observation présentée, à l'une des M classes connues *a priori* ou à la classe de rejet de distance ω_d si l'observation est éloignée de toutes les M classes, ou à la classe de rejet d'ambiguïté ω_a si elle appartient au moins à deux classes de l'ensemble d'apprentissage. Lorsque la nouvelle observation X est affectée à la classe ω_k avec $k \in \{1, \dots, M\}$, les caractéristiques (paramètres du modèle) de celle-ci sont mises à jour. La mise à jour en continu des paramètres des modèles permet de suivre en temps réel l'évolution des classes correspondant aux modes de fonctionnement. Les observations affectées à la classe ω_d seront utilisées pour mettre en évidence l'apparition de nouveaux modes de fonctionnement du système. Le diagnostic adaptatif permet de déterminer à chaque instant l'état dans lequel le système se trouve et éventuellement de décider s'il est nécessaire de créer une nouvelle classe correspondant à un nouveau mode de fonctionnement. Lorsque des nouveaux sont détectés, l'expert ou l'utilisateur les labellise en termes de modes de fonctionnement des nouvelles classes identifiées. La confirmation et la labellisation se feront en fonction du nombre minimal d'observations affectées à la classe ω_d par le module de décision et en fonction de la similarité des observations contenues dans ω_d [TRA 10].

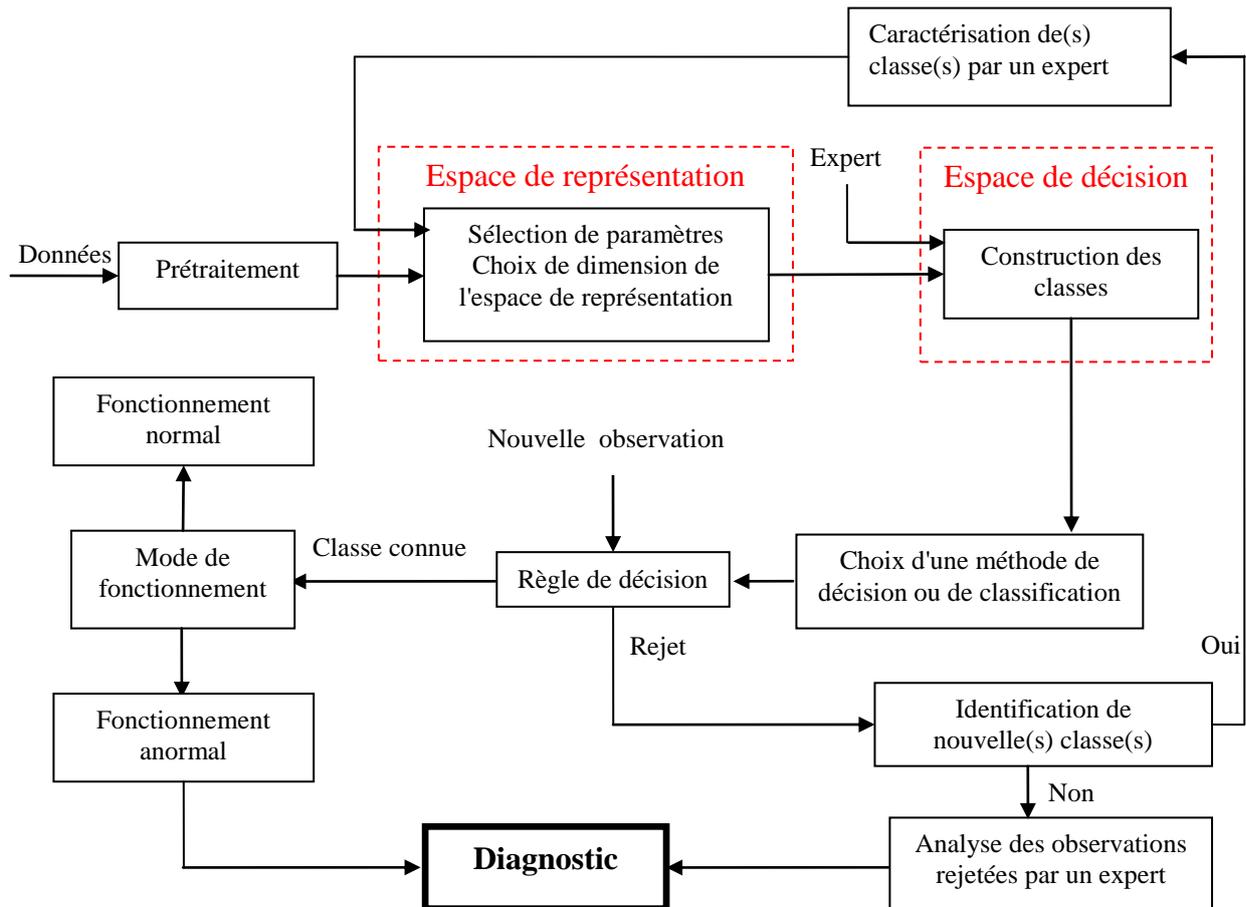


Figure 2.6. Structure d'un système de diagnostic par RfF

2.3. Reconnaissance des formes floue

Le principe de diagnostic par reconnaissance des formes étant défini, nous aborderons dans ce qui suit en détail l'apport de l'approche floue dans un système de diagnostic.

2.3.1. Approche floue

L'étiquetage des observations est fait par un expert humain. Cet étiquetage est une source d'imprécision puisque la connaissance de l'expert sur le système n'est jamais parfaite. De plus, une observation située au centre d'une classe et une observation située en bordure de cette même classe n'ont pas la même représentativité de la classe, pourtant elles sont affectées à la même classe avec la même valeur d'appartenance, cela crée une autre source d'incertitude. Le bruit, dû à l'utilisation des capteurs ou au système lui-même, constitue une troisième source d'incertitude [MOU 02].

Pour faire face à ces limitations, Zadeh a introduit en 1965 la théorie des ensembles flous.

Dans la théorie ensembliste classique, un sous ensemble d'un ensemble de référence est constitué des éléments qui possèdent une ou plusieurs propriétés communes caractéristiques de ce sous ensembles. Chaque élément x de l'univers de référence E est ainsi caractérisé par son appartenance ou non appartenance aux sous ensembles E_k définis. Cela peut être décrit par une fonction binaire abrupte appelée fonction caractéristique $u_{E_k}(x): E \rightarrow \{0,1\}$, laquelle vérifie:

$$u_{E_k}(x) = \begin{cases} 1 & \text{si } x \in E_k \\ 0 & \text{sinon} \end{cases} \quad (2.22)$$

De même, il est possible de définir formellement un sous ensemble flou F de E comme sous ensemble généralisé de E caractérisé par une fonction d'appartenance $u_F: E \rightarrow [0,1]$. Chaque quantité $u_F(x)$ est interprétée comme le degré d'appartenance de l'élément x à F . La figure 2.7 montre la différence de concept entre une fonction caractéristique et une fonction d'appartenance.

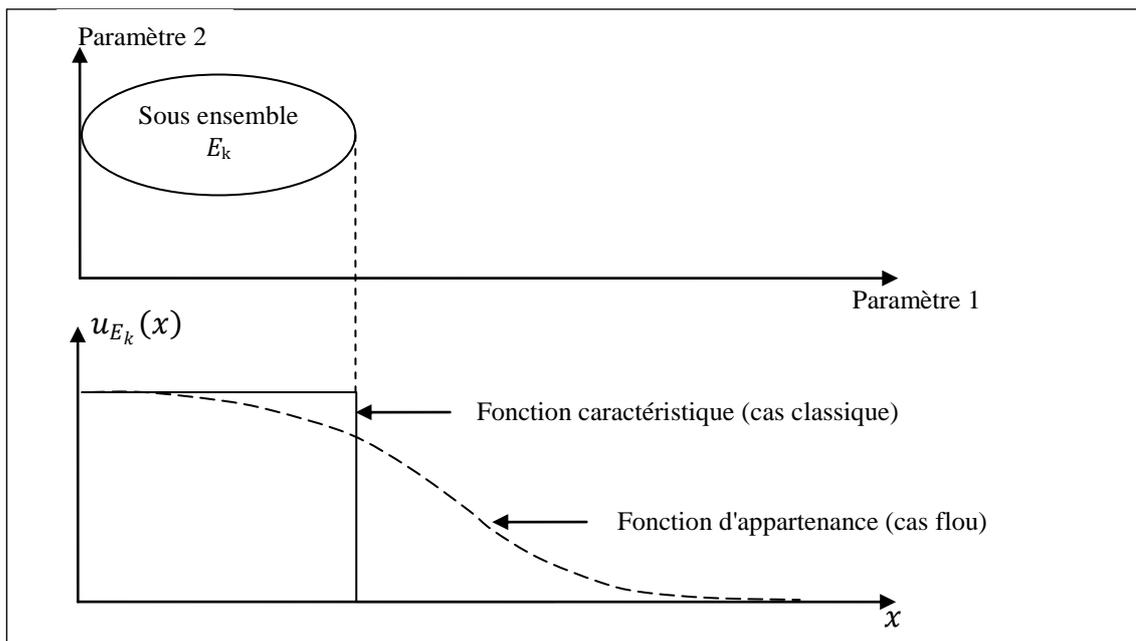


Figure 2.7. Concept d'appartenance au sens classique et au sens flou [MOU 02]

Eléments caractéristiques des sous ensembles flous

- Le noyau $Noy(F)$ d'un sous ensemble flou F est l'ensemble des éléments de E dont le degré d'appartenance à F vaut 1:

$$Noy(F) = \{x \in E \mid u_F(x) = 1\} \quad (2.23)$$

- Le support $Supp(F)$ d'un ensemble flou F est l'ensemble des éléments de E dont le degré d'appartenance à F est non nul:

$$Supp(F) = \{x \in E \mid u_F(x) > 0\} \quad (2.24)$$

- La hauteur $h(F)$ d'un ensemble flou F est la valeur maximale de la fonction d'appartenance u_F :

$$h(F) = \sup_{x \in E} u_F(x) \quad (2.25)$$

Si $h(F) = 1$, on dit que le sous ensemble flou F est normalisé.

- La cardinalité $|F|$ d'un ensemble flou F est la quantité (floue) des éléments de E qui appartiennent à F :

$$|F| = \sum_{x \in E} u_F(x) \quad (2.26)$$

- L' α -coupe F_α d'un ensemble flou F est l'ensemble des éléments de E qui appartiennent à F avec un degré au moins égale α :

$$F_\alpha = \{x \in E \mid u_F \geq \alpha\} \quad (2.27)$$

L' α -coupe est un procédé qui permet à partir de sous ensembles flous de revenir à la notion de sous ensembles classiques. Ainsi, F_α est un sous ensemble décrit par sa fonction caractéristique comme définie par l'équation (2.22).

La figure 2.8 illustre les principales notions définies ci-dessus

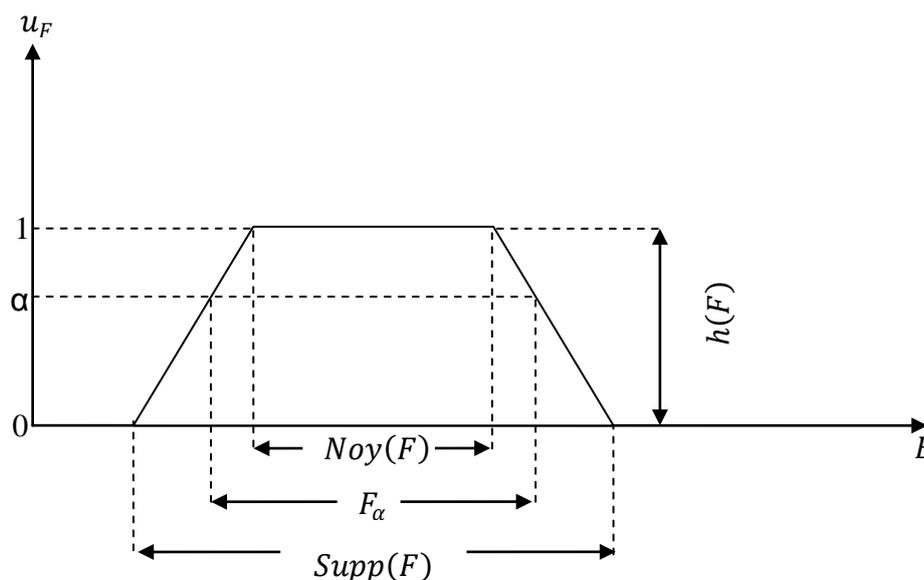


Figure 2.8. Principaux éléments caractéristiques d'un sous ensemble flou F

Opérations sur les sous ensembles flous :

L'un des intérêts essentiels de la notion d'ensemble flou réside dans la possibilité d'étendre les opérateurs ensemblistes usuels. Nous présentons ici les principales opérations utilisées pour la manipulation de deux sous ensembles flous F et G :

➤ L'égalité:

$$F = G \Leftrightarrow \forall x \in E, u_F(x) = u_G(x) \quad (2.28)$$

➤ L'inclusion:

$$F \subseteq G \Leftrightarrow \forall x \in E, u_F(x) \leq u_G(x) \quad (2.29)$$

➤ L'union:

$$\forall x \in E, u_{F \cup G}(x) = \max(u_F(x), u_G(x)) \quad (2.30)$$

➤ L'intersection:

$$\forall x \in E, u_{F \cap G}(x) = \min(u_F(x), u_G(x)) \quad (2.31)$$

➤ Le complément:

$$\forall x \in E, u_{\bar{F}}(x) = 1 - u_F(x) \quad (2.32)$$

où, \bar{F} est le complément de F dans E .

Normes et conormes triangulaires

Les normes triangulaires (t-normes) et les conormes triangulaires (t-conormes) permettent de généraliser respectivement les opérations ensemblistes d'intersection et d'union sur les sous ensembles flous. Pour que cette généralisation soit correcte, un certain nombre de propriétés doivent être vérifiées:

➤ t-norme: la norme triangulaire est la fonction $T: [0,1] \times [0,1] \rightarrow [0,1]$ qui possède les propriétés suivantes, pour tout $y, z, t, v \in [0,1]$:

- commutativité: $T(y, z) = T(z, y)$
- associativité: $T(y, T(z, t)) = T(T(y, z), t)$
- monotonie: $T(y, z) = T(t, v)$ si $y \leq t$ et $z \leq v$
- élément neutre 1: $T(y, 1) = y$

➤ t-conorme: la conorme triangulaire est la fonction \perp à savoir une application de $[0,1] \times [0,1]$ dans $[0,1]$ vérifiant les propriétés de, associativité, monotonie, et admettant 0 pour élément neutre:

$$\perp(y, 0) = y \quad \forall y \in [0,1] \quad (2.33)$$

Le tableau 2.1 regroupe les t-normes et les t-conormes les plus courantes.

Nom	t-normes $T(y, z)$ (intersection floue)	t-conormes $\perp(y, z)$ (union floue)
min et max de Zadeh	$\min(y, z)$	$\max(y, z)$
Produit et somme algébrique (Bandler)	$y \cdot z$	$y + z - y \cdot z$
Produit et somme bornés (Lukasiewicz)	$\max(y + z - 1, 0)$	$\min(y + z, 1)$

Tableau 2.1. Principales t-normes et t-conormes [GRI 07].

Une t-norme et une t-conorme sont dites duales pour l'opération de complémentation standard si elles satisfont aux lois de De Morgan [DEN 01]:

$$1 - \perp(y, z) = T(1 - y, 1 - z) \quad (2.34)$$

et:

$$1 - T(y, z) = \perp(1 - y, 1 - z) \quad (2.35)$$

Une application de cette notion en diagnostic consiste à supposer que la variable y , décrivant le mode de fonctionnement de système, ne prend pas une seule valeur, mais simultanément plusieurs valeurs à des degrés différents. Formellement, le domaine de y est donc l'ensemble $[0,1]^E$ des sous ensembles flous de E . Par exemple, la proposition $y = F$, avec $F \in [0,1]^E$, signifie que le système se trouve dans chaque mode $\omega \in E$ avec un degré $u_F(\omega) \in [0,1]$. La quantité $u_F(\omega)$ est appelée degré d'appartenance au mode ω . Il est quelquefois judicieux d'imposer la condition [DEN 01]:

$$\sum_{k=1}^M u_F(\omega_k) = 1 \quad (2.36)$$

Qui généralise la notion d'unicité du mode de fonctionnement (F est alors un singleton flou de E). Pour chaque valeur X du vecteur d'observations, il s'agit alors de définir un vecteur d'appartenance $Z = \{u_k(X)\}_{k=1}^M \in [0,1]^M$, où $u_k(X)$ désigne une évaluation du degré d'appartenance du système au mode de fonctionnement ω_k .

La fonction $u_k: X \rightarrow u_k(X)$ est appelée fonction d'appartenance associée au mode ω_k .

2.3.2. Méthodes floues de classification supervisée

Dans certains cas, on dispose d'un ensemble d'apprentissage étiqueté de la forme $\mathcal{E} = \{(X_i, Y_i)\}_{i=1}^N$, Y_i étant l'étiquette floue de l'exemple:

$$Y_i = (u_{i,1}, \dots, u_{i,M}) \quad (2.37)$$

Dans l'expression ci-dessus, $u_{i,k}$ désigne le degré d'appartenance du système au mode de fonctionnement k , pour l'exemple i . ces degrés d'appartenance peuvent être obtenus par interrogation d'un expert, ou par l'un des algorithmes de classification floue qui sera décrit dans la section suivante.

Le problème consiste, dans ce cas, à interpréter les données d'apprentissage de manière à fournir une évaluation des fonctions d'appartenance pour tout nouveau point X . Parmi les méthodes qui ont été proposées pour résoudre ce problème, on peut citer les extensions floues de la méthode des K plus proches voisins et les réseaux de neurones.

Des extensions floues de la méthode des K plus proches voisins ont été proposées par Jozwik 1983, Keller, Gray et Givens 1985, Bezdek, Chuah et Leep 1986 et Béreau 1986. L'approche décrite par Jozwik et Bezdek consiste à définir le degré d'appartenance de X à la classe k comme la moyenne des degrés d'appartenance à cette classe parmi les K plus proches voisins de X [DEN 01]:

$$u_k(X) = (1/K) \sum_{i \in \Phi_K(X)} u_{i,k} \quad (2.38)$$

où $\Phi_K(X)$ désigne l'ensemble des indices des K plus proches voisins de X dans l'ensemble d'apprentissage, selon une certaine métrique (par exemple, la métrique euclidienne).

Les règles proposées par Keller et Béreau sont a priori plus satisfaisantes, car elles font intervenir également les distances aux voisins de X . Keller propose l'expression suivante :

$$u_k(X) = \left(\sum_{i \in \Phi_K(X)} u_{i,k} \|X - X_i\|^{-2/(m-1)} \right) / \left(\sum_{i \in \Phi_K(X)} \|X - X_i\|^{-2/(m-1)} \right) \quad (2.39)$$

où m est un coefficient.

La règle proposée par Béreau consiste à poser :

$$u_k(X) = \max_{i \in \Phi_K(X)} u_{i,k} \exp[-\eta(\|X - X_i\|/d_k)^2] \quad (2.40)$$

où d_k est la distance moyenne entre vecteurs d'apprentissage ayant un degré d'appartenance à la classe ω_k supérieur à un certain seuil, et η un coefficient. Par rapport

à la précédente, cette règle présente la particularité d'affecter des degrés d'appartenance faibles aux points éloignés de l'ensemble d'apprentissage.

2.3.3. Classification floue non supervisée

Le problème central en reconnaissance des formes floue réside dans l'apprentissage des fonctions d'appartenance à partir des données. Lorsque celles-ci se composent de N vecteurs $\{X_i\}_{i=1}^N$ non étiquetés (apprentissage non supervisé). Ce problème rejoint celui de la classification automatique en analyse des données, et peut être formalisé comme la recherche d'une partition floue des observations, généralisant la notion classique de partition d'un ensemble de points.

Une partition de l'ensemble d'apprentissage X_a en M classes peut être décrite par une matrice U à N lignes et M colonnes, de terme général $u_{i,k}$, et telle que $u_{i,k} = 1$ si X_i appartient à la classe k , et $u_{i,k} = 0$ sinon. Tout vecteur X_i appartient à une seule classe, ce qui implique:

$$\sum_{k=1}^M u_{i,k} = 1 \quad \forall i \quad (2.41)$$

En outre, on peut supposer qu'aucune classe n'est vide, ce qui implique que:

$$\sum_{i=1}^N u_{i,k} > 0 \quad \forall k \quad (2.42)$$

Une matrice de partition floue se définit comme une matrice U de terme général $u_{i,k} \in [0,1]$ vérifiant les équations (2.41) et (2.42) précédentes. La quantité $u_{i,k}$ s'interprète alors comme degré d'appartenance (prenant n'importe quelle valeur réelle entre 0 et 1) de l'objet i à la classe k .

2.3.3.1. Algorithme FCM

L'algorithme de FCM (Fuzzy C- Means) ou des C moyennes floues, est l'un des premiers algorithmes proposés pour construire automatiquement une partition floue d'un ensemble de vecteurs de R^d . Il se base sur une optimisation d'une partition initiale des données. Cette partition est caractérisée par un ensemble de prototype correspondant à des centroïdes ou centres des classes.

Le principe de fonctionnement de l'algorithme ainsi que ses avantages et ses inconvénients sont décrits ci-dessous.

2.3.3.1.1. Principe

Soit l'ensemble d'apprentissage $X_a = \{X_1, \dots, X_N\}$ défini dans R^d que l'on souhaite partitionner en M classe. Soit $V = (V_1, \dots, V_M)$ l'ensemble des centroïdes caractérisant ces classes. L'algorithme des C moyennes floues effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur. Il existe toute une famille de fonctions d'erreur associées à cet algorithme qui se distinguent par des valeurs différentes prises par paramètre réglable m , appelé indice de flou et qui détermine le degré de flou de la partition obtenue. L'algorithme de FCM est basé sur la minimisation de la fonction objectif suivante:

$$J_m(U, V) = \sum_{k=1}^M \sum_{i=1}^N u_{i,k}^m \|X_i - V_k\|_A^2 \quad (2.43)$$

Pour tout k ($1 \leq k \leq M$), V_k est un vecteur à d composantes qui représente le prototype de la $k^{\text{ème}}$ classe, $m > 1$ est l'indice flou.

$$\|X_i - V_k\|_A^2 = (X_i - V_k)^t A (X_i - V_k) \quad (2.44)$$

est la norme de distance entre l'observation X_i et le centre V_k au sens de la métrique induite par la matrice symétrique définie positive A .

La forme des classes dans l'algorithme FCM est déterminée par le choix de la matrice A , si cette dernière est la matrice d'identité, la distance est la distance euclidienne et les classes obtenues sont de forme sphérique. A peut être définie comme l'inverse de la matrice de covariance de l'ensemble X_a : $A = \tilde{\Sigma}^{-1}$, avec $\tilde{\Sigma} = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})(X_i - \bar{X})^t$. où, \bar{X} est la moyenne de l'ensemble X_a . Dans ce cas, la matrice A induit la norme Mahalanobis. Avec cette norme, les classes sont représentées par des hyper-ellipses, comme le montre la figure 2.9.

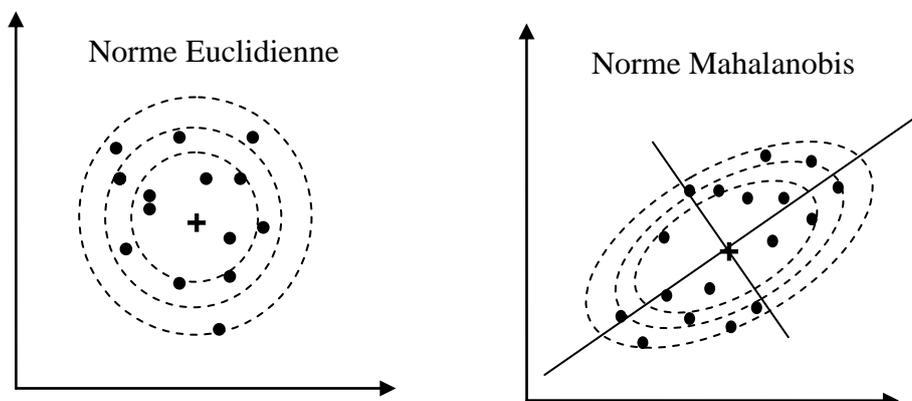


Figure 2.9. Mesures de distance pour la classification [KEM 04]

Le paramètre m défini dans $]1, \infty[$ introduit le degré de flou de la partition. Il permet de jouer sur le degré de chevauchement autorisé entre les classes. Quand $m \rightarrow 1$, la partition tend vers une partition nette (c'est-à-dire non floue, $m = 1$: Algorithme de HCM); au contraire, quand $m \rightarrow \infty$, la partition devient de plus en plus floue. Généralement on utilise $m = 2$.

L'algorithme général se déroule finalement selon les étapes suivantes:

Algorithme 1: l'algorithme de FCM

○ *Paramétrage:*

Fixer le nombre de classe M tel que $2 \leq M < N$, N étant le nombre de données.

Fixer le degré de flou m .

Choisir une norme pour le calcul des distances $\|\cdot\|_A$.

Choisir le seuil d'arrêt ϵ et le nombre maximal des itérations T .

○ *Initialisations :*

Initialiser le compteur de boucle $t \leftarrow 0$.

Tirage au hasard des prototypes $V_0 = (V_1^{(0)}, \dots, V_M^{(0)})$

○ *Itérations:*

Répéter

$t \leftarrow t + 1$

1) Calcul de la matrice de partition U_t comme suit:

a) Chercher I_i et \dot{I}_i :

$$I_i = \{k/1 \leq k \leq M \text{ et } \|X_i - V_k\| = 0\}$$

$$\dot{I}_i = \{1, 2, \dots, M\} - I_i$$

b) pour l' $i^{\text{ème}}$ donnée X_i , calculer les degrés d'appartenance selon que l'on est dans l'un ou l'autre des deux cas suivants

i. si $I_i = \emptyset$:

$$u_{i,k} = \left[\sum_{l=1}^M (\|X_i - V_k\|_A / \|X_i - V_l\|_A)^{2/(m-1)} \right]^{-1} \quad (2.45)$$

ii. sinon pour tout $k \in \dot{I}_i$, $u_{i,k} = 0$, et pour tout $k \in I_i$, fixer une valeur pour $u_{i,k}$ de telle sorte que:

$$\sum_{i \in I_i} u_{i,k} = 1$$

2) Calculer les prototypes $V_t = (V_1^{(t)}, \dots, V_M^{(t)})$ à l'aide de la formule suivante: pour $k=1$ allant jusqu'à M

$$V_k^{(t)} = (\sum_{i=1}^N u_{i,k}^m X_i) / (\sum_{i=1}^N u_{i,k}^m) \quad (2.46)$$

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \epsilon$

Le calcul de U fait intervenir deux cas. Dans le premier (i), aucun centroïde de classe ne correspond avec la donnée X_i . Dans le second cas (ii), la formule (2.45) n'est alors pas applicable et X_i est attribué à la classe (aux classes) dont le centroïde(s) lui est (sont) identique(s).

2.3.3.1.2. Avantages et inconvénients

Le principal avantage de l'algorithme FCM par rapport aux algorithmes plus classiques provient de l'introduction des degrés d'appartenances $u_{i,k}$. Grâce à eux le processus d'optimisation itératif est rendu beaucoup plus robuste, notamment en permettant de prendre en compte les recouvrements entre les classes. Il permet ainsi d'obtenir des partitions plus pertinentes et plus proches de la réalité. En outre, ces degrés permettent de prendre des décisions nuancées pour l'assignation d'une forme à une classe, ce qui s'avère très intéressant pour toute forme de classification.

L'algorithme possède aussi quelques inconvénients, on peut citer par exemple le problème de la sensibilité à l'initialisation (différentes initialisations peuvent aboutir à différentes partitions), la nécessité d'imposer le nombre de classes M a priori, la contrainte liant les degrés d'appartenance d'un point donné, ou encore le manque de flexibilité sur la forme de classe qu'il peut détecter.

Les figures suivantes illustrent les principales nuances auxquelles on se trouve confrontés lors de l'utilisation de la méthode de FCM sous la forme préliminaire; il s'agit essentiellement d'une meilleure immunité face au bruit, i.e. une moindre sensibilité aux points non significatifs, et une corrélation, intrinsèque, exclusive entre le degré d'appartenance d'un vecteur à une classe donnée et sa représentativité de cette même classe [KHO 07].

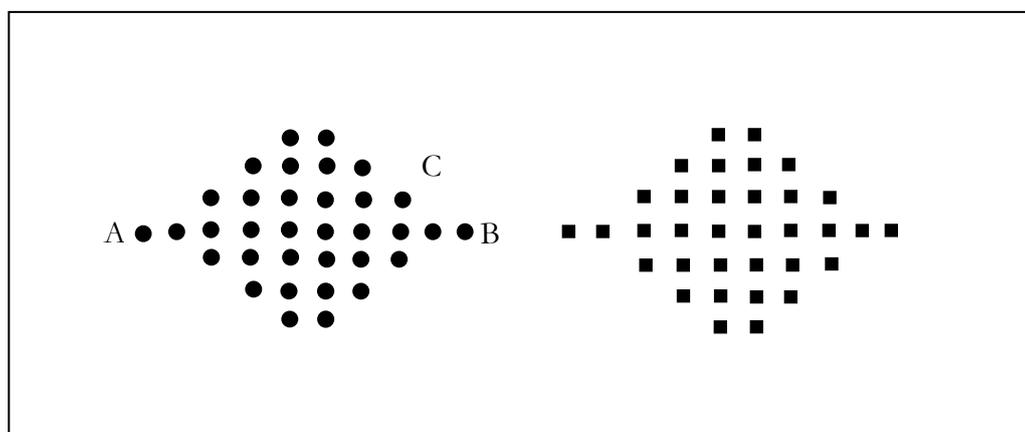


Figure 2.10. Exemple de deux classes symétriques

Dans l'exemple illustré à la figure 2.10, l'approche des FCM distingue les cas des points A et B, puisque leurs distances au centre du groupe de droite sont différentes, alors que, si on ne s'intéresse qu'à leurs taux de représentativité de la classe de gauche ils représentent deux cas symétriques. Cette symétrie est brisée, en ce qui concerne leur parenté au centre du groupe de gauche, dans le cas des FCM, à cause de corrélation entre leurs degrés d'appartenance aux deux groupes. Dans ce cas, le degré d'appartenance à la classe gauche est le complément à 1 de celui à droite. Avec la même méthode, le degré d'appartenance du point C au groupe de gauche est plus petit que celui du point A, et ce bien qu'il soit plus proche que A du centre de ce groupe [KHO 07].

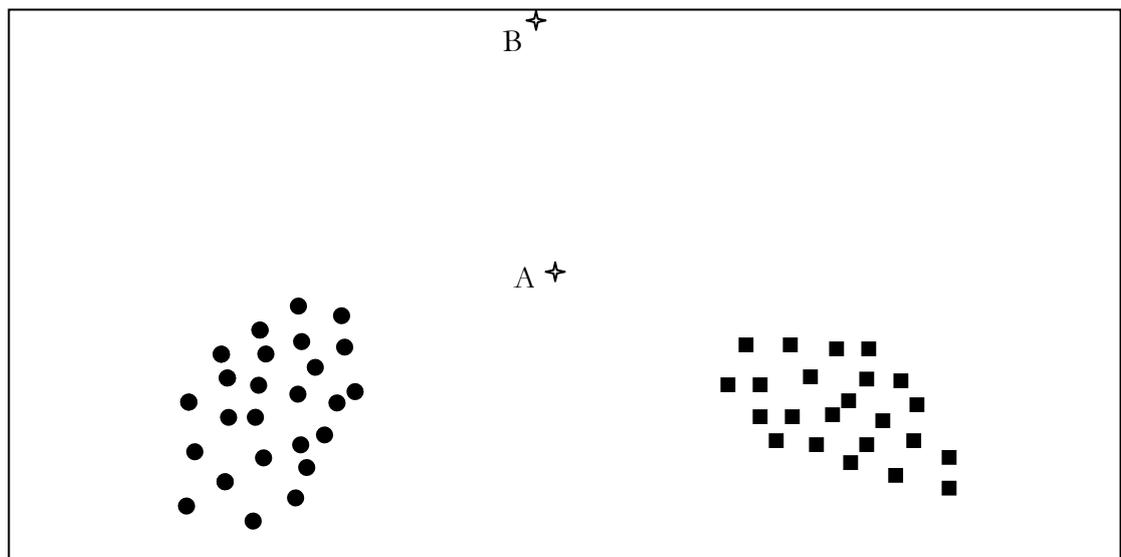


Figure 2.11. Exemple illustratif de deux points l'un est plus éloigné que l'autre des centres des deux groupes

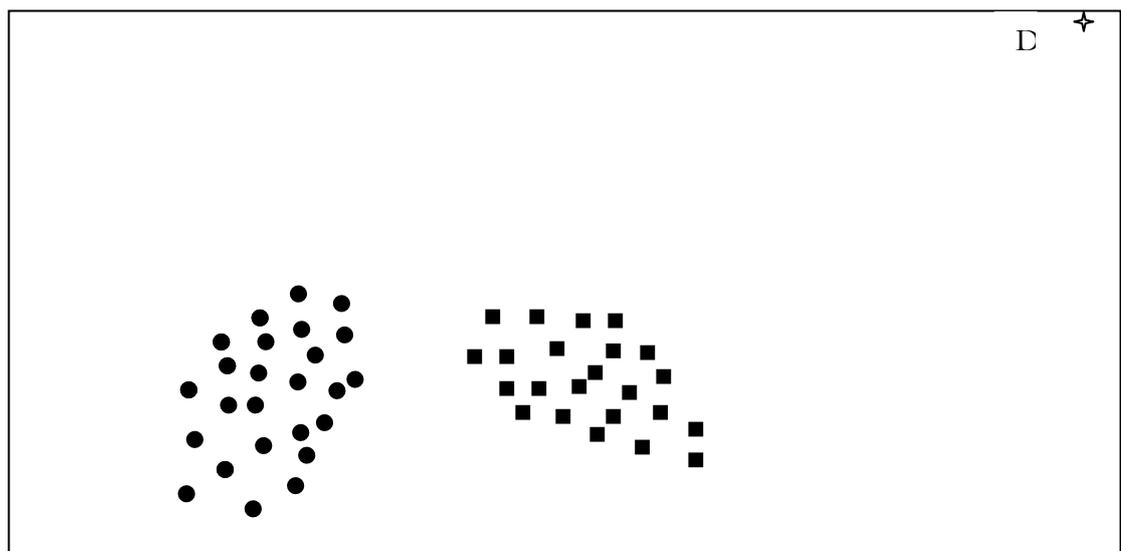


Figure 2.12. Exemple illustratif des points inutiles qui peuvent affecter la forme des fonctions d'appartenance

Dans le cas de la figure 2.11, l'approche FCM basée sur la condition (2.41) donne des degrés d'appartenance comparables pour A et B et proches de 1/2, puisqu'ils sont, tous les deux, presque à mi-distance de deux centres (même si B est plus éloigné des deux groupes).

Sur l'exemple de la figure 2.12, il est souhaitable que l'effet de perturbation dû au point D influe le moins possible sur le calcul des fonctions d'appartenance des deux groupes.

La plupart de ces difficultés peuvent cependant être contournées via d'autres variantes dérivées de la méthode FCM, détaillées ci-après.

2.3.3.2. Les variantes de des C moyennes floues

Différentes adaptations ont été opérées sur l'algorithme FCM, notamment pour pouvoir traiter les problèmes que nous avons cités précédemment. Nous décrivons ici quelques unes des variantes qui dérivent des C moyennes floues.

2.3.3.2.1. L'approche de GK

Une limitation évidente de l'algorithme FCM est la nécessité de définir à l'avance une métrique unique A pour le calcul des distances aux centres de chacune des classes, ce qui présente un inconvénient lorsque celles-ci ont des formes ou des volumes différents.

Une variante proposée par Gustafson et Kessel consiste à associer une matrice A_k à chaque classe k , et à déterminer les A_k par apprentissage: on parle alors de distance adaptative qui permet de détecter des classes de forme ellipsoïdale.

Soit l'ensemble $A = \{A_k\}_{k=1}^M$, la fonction objectif utilisée par Gustafson et Kessel est définie par:

$$J_m^{GK}(U, V) = \sum_{k=1}^M \sum_{i=1}^N u_{i,k}^m \|X_i - V_k\|_{A_k}^2 \quad (2.47)$$

sous les contraintes suivantes:

$$\det(A_k) = \rho_k \quad (2.48)$$

$\rho_k > 0$ garantit que A_k soit définie positive.

L'algorithme de classification de Gustafson et Kessel (GK), appelé aussi FCC (Fuzzy C-covariance), peut se formuler ainsi:

Algorithmme 2: l'algorithme de GK

○ *Paramétrage:*

Fixer le nombre de classe M tel que $2 \leq M < N$, N étant le nombre de données.

Fixer le degré de flou m .

Choisir le seuil d'arrêt ϵ et le nombre maximal des itérations T .

○ *Initialisations :*

Initialiser le compteur de boucle $t \leftarrow 0$.

Tirage au hasard des prototypes $V_0 = (V_1^{(0)}, \dots, V_M^{(0)})$

Initialiser l'ensemble des matrices de covariance $A^{(0)}$ respectant $\det(A_k) = \rho_k > 0$

○ *Itérations:*

Répéter

$t \leftarrow t + 1$

1) Calcul de la matrice de partition U_t comme suit:

$$u_{i,k} = \left[\sum_{l=1}^M (\|X_i - V_k\|_A / \|X_i - V_l\|_A)^{2/(m-1)} \right]^{-1} \quad (2.49)$$

2) Calculer les prototypes $V_t = (V_1^{(t)}, \dots, V_M^{(t)})$ à l'aide de la formule suivante:

pour $k=1$ allant jusqu'à M

$$V_k^{(t)} = (\sum_{i=1}^N u_{i,k}^m X_i) / (\sum_{i=1}^N u_{i,k}^m) \quad (2.50)$$

$$A_k = [\rho_k \det(\tilde{\Sigma}_k)]^{1/n} \tilde{\Sigma}_k^{-1} \quad \forall k \quad (2.51)$$

Où $\tilde{\Sigma}_k$ est la matrice de covariance floue de la classe k définie par :

$$\tilde{\Sigma}_k = (\sum_{i=1}^N u_{i,k}^m)^{-1} \sum_{i=1}^N u_{i,k}^m (X_i - V_k)(X_i - V_k)^t \quad (2.52)$$

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \epsilon$

L'algorithme de FCC étant plus sensible que FCM aux conditions initiales, une stratégie souvent recommandée consiste à prendre, comme solution initiale de FCC, la partition obtenue par FCM.

2.3.3.2.2. Approche de C moyennes possibilistes

Une autre variante intéressante de l'algorithme FCM proposée par Krishnapuram et Keller est l'algorithme PCM (Possibilistic C-Means), ou algorithme des C moyennes possibilistes, son principe est de caractériser les classes, les unes par rapport aux autres, de manière absolue. Pour cela, l'idée consiste à rechercher une matrice U de terme général $u_{i,k} \in [0,1]$ ne vérifiant pas nécessairement la condition de normalisation (2.41), donc la

minimisation de critère (2.43) a comme solution triviale l'attribution de degrés d'appartenance nuls pour chaque donnée. Pour éviter ce problème, le critère est modifié comme suit:

$$J_m^{PCM}(U, V) = \sum_{k=1}^M \sum_{i=1}^N u_{i,k}^m \|X_i - V_k\|_A^2 + \sum_{k=1}^M w_k \sum_{i=1}^N (1 - u_{i,k})^m \quad (2.53)$$

Les coefficients w_k sont des nombres positifs homogènes à des distances carrées. Plus précisément, w_k est le carré de la distance séparant le centre de la classe k de l'ensemble des points dont le degré d'appartenance à cette même classe est égal à 1/2.

La première partie de ce critère est identique à celle de FCM. Elle vise toujours à minimiser la distance au sein de chacune des classes. Le second terme vise quant à lui à maximiser les degrés d'appartenance pour qu'ils ne soient pas tous nuls.

Dans ce critère, la matrice U représente toujours une matrice de partition floue $M * N$, elle est constituée des degrés d'appartenance $u_{i,k}$ des N observations au M classes. Ceux-ci satisfont les contraintes suivantes:

$$\forall i \in \{1, \dots, N\}, \forall k \in \{1, \dots, M\}, u_{i,k} \in [0, 1]; \forall k, \max_k u_{i,k} > 0; \forall k, 0 < \sum_{i=1}^N u_{i,k} \leq N \quad (2.54)$$

La condition de normalisation a été remplacée par une simple contrainte sur l'existence, pour chaque prototype, d'au moins une donnée y appartenant. Pour que ces contraintes soient satisfaites et que $J_m^{PCM}(U, V)$ puisse être minimisé, les prototypes et les degrés d'appartenance sont définis par l'algorithme 3.

Algorithme 3: l'algorithme de PCM

○ *Paramétrage:*

Fixer le nombre de classe M tel que $2 \leq M < N$, N étant le nombre de données.

Fixer le degré de flou m .

Choisir une norme pour le calcul des distances $\|\cdot\|_A$.

Choisir le seuil d'arrêt ϵ et le nombre maximal des itérations T .

○ *Initialisations :*

Initialiser le compteur de boucle $t \leftarrow 0$.

Initialiser la partition en utilisant par exemple l'algorithme de FCM

Calculer les w_k à l'aide de la formule suivante:

$$w_k = (\sum_{i=1}^N u_{ik}^m \|X_i - V_k\|_A^2) / \sum_{i=1}^N u_{ik}^m \quad (2.55)$$

○ *Itérations:*

Répéter

$$t \leftarrow t + 1$$

1) Calcul de la matrice de partition U_t comme suit:

$$u_{i,k} = \left[\sum_{l=1}^M (1 + \|X_i - V_k\|_A^2 / w_k)^{1/(m-1)} \right]^{-1} \quad \forall i, k \quad (2.56)$$

2) Calculer les prototypes $V_t = (V_1^{(t)}, \dots, V_M^{(t)})$ à l'aide de la formule suivante:
pour $k=1$ allant jusqu'à M

$$V_k^{(t)} = (\sum_{i=1}^N u_{i,k}^m X_i) / (\sum_{i=1}^N u_{i,k}^m) \quad (2.57)$$

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \epsilon$

Les PCM, bien qu'incarnant une notion de typicalité, présentent des performances parfois insatisfaisantes. En particulier, il a été observé que pour les ensembles des données structurés en des classes non trivialement séparées, cet algorithme a la mauvaise tendance de produire des classes co-centriques, c.-à-d les classes obtenues ont des centres très proches, voire confondus [KHO 07]. Pour y remédier Khodja L. [KHO 07] a présenté une version modifiée de l'algorithme PCM que nous évoquerons dans le paragraphe suivant.

2.3.3.2.3. Approche de C moyennes possibilistes modifiée

Selon Khodja, le rapprochement des centres observé avec l'algorithme PCM n'est pas uniquement dû à une mauvaise initialisation de la partition. En effet, lorsque les deux centres sont confondus, la méthode a été probablement mal initialisée. Cependant, ceci n'explique pas la décroissance très rapide de la distance inter-centres calculée à l'aide de l'approche PCM. Khodja [KHO 07] a opté pour la limitation de la contribution des points les plus éloignés d'un centre donné dans le calcul des coordonnées de ce centre, sachant que la réduction des valeurs de l'indice du flou m , proposée par Krishnapuram et Keller pour obvier au problème de confusion des centres s'est avérée insuffisante. Le nouvel algorithme proposé par Khodja repose sur le remplacement de la formule des degrés d'appartenance (2.56) par la Formule suivante:

$$u_{i,k} = \left[\sum_{l=1}^M \left(1 + \frac{\|X_i - V_k\|_A^2}{w_k} \right)^{\frac{m}{(m-1)}} \right]^{-1} \quad \forall i, k \quad (2.58)$$

L'exposant au dénominateur est augmenté, ce qui assure la rapidité dans la décroissance recherchée. Cette approche, appelé MPCM (Modified Possibilistic C-Means), présente l'avantage de sauvegarder les apports espérés de l'approche possibiliste, tout en éliminant l'inconvénient fâcheux de confusion des centres.

Le critère proposé par Khodja est le suivant:

$$J_m^{MPCM}(U, V) = \sum_{k=1}^M \sum_{i=1}^N u_{i,k}^m \|X_i - V_k\|_A^{2m} + \sum_{k=1}^M w_k \sum_{i=1}^N (1 - u_{i,k})^m \quad (2.59)$$

2.3.3.3. Les problèmes en classification

2.3.3.3.1. Validation du nombre des classes

Les algorithmes de classification floue précédents nécessitent la connaissance à priori du nombre des classes, ce qui n'est pas toujours possible. Différentes partitions sont ainsi obtenues pour différentes valeurs de M . On est alors obligé de définir un critère, ou une fonction de validité, mesurant la performance de la classification pour choisir le nombre optimal de classe M . C'est ce qu'on appellera indice de validité des classes (cluster validity index).

Le processus pour le calcul de l'indice de validation des classes est résumé par les étapes suivantes:

- 1) Appliquer l'algorithme de classification pour différents valeurs de M avec $M = 2, \dots, M_{max}$. (M_{max} est fixé par l'utilisateur).
- 2) Calculer l'indice de validité pour chaque partition obtenue à l'étape précédente.
- 3) Choisir le nombre optimal M^* de classes.

Nous présentons au tableau suivant quelques critères de validation les plus utilisés ainsi que leurs règles d'utilisation. Les deux premiers critères sont conçus spécialement pour l'algorithme de FCM, les autres critères peuvent être appliqués à n'importe quel algorithme de coalescence floue.

Critères	Indice de validité	Règle d'utilisation
Coefficient de partition	$C_{CP}(M) = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^M u_{ik}^2$	$M^* = \max_{M=2, M_{max}} [C_{CP}(M)]$
Entropie de classification	$C_{EC}(M) = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^M u_{ik} \cdot \ln(u_{ik})$	$M^* = \min_{M=2, M_{max}} [C_{EC}(M)]$
Critère de compacité et de séparabilité	$C_{CS}(M) = \frac{C_o}{S_e}$	$M^* = \min_{M=2, M_{max}} [C_{CS}(M)]$
Hypervolume flou	$C_{HF}(M) = \sum_{k=1}^M [\det(\tilde{\Sigma}_k)]^{\frac{1}{2}}$	$M^* = \min_{M=2, M_{max}} [C_{HF}(M)]$

Tableau 2.2. Critères de validité des classes

Avec,

$C_o = \frac{1}{N} \sum_{k=1}^M \sum_{i=1}^N [u_{ik} \cdot \|X_i - V_k\|]^2$ est la compacité des classes,

$S_e = [\min_{\substack{k=1, M, j=1, M \\ k \neq j}} \|V_k - V_j\|]^2$ est la séparabilité,

$\tilde{\Sigma}_k = S_k / (\sum_{i=1}^N u_{ik}^m)$ est la matrice de covariance floue de la classe k , où S_k est l'entropie correspondant à la classe k défini par:

$S_k = \sum_{i=1}^N u_{ik}^m \cdot (X_i - V_k) \cdot (X_i - V_k)^t$ est la matrice de dispersion floue.

Ammor et Al. [AMM 07] ont présenté les limites et les inconvénients des critères précédents. Ils ont proposé un nouveau critère, appelé Maximum d'entropie, qui donne des meilleures performances, dans le cas de fort chevauchement. Ce critère est donné comme suit:

$$C_{MEP}(M) = \frac{1}{M} \sum_{k=1}^M E_k + \ln(M) \quad (2.60)$$

avec, $E_k = -\sum_{j \in C_k} P_{jk} \ln(P_{jk})$ est l'entropie correspondant à la classe k

où, $P_{ik} = \exp(-M\|V_i - V_k\|^2) / \sum_{j \in M_k} \exp(-M\|V_i - V_k\|^2)$

Le nombre optimal M^* de classe sera celui pour lequel la valeur de C_{MEP} est maximale.

2.3.3.3.2. Méthodes d'initialisation de la partition

Le choix des paramètres initiaux est un problème vaste de la recherche opérationnelle et de nombreuses méthodes sont possibles dans le cas de classification:

- Tirage aléatoire des centres des classes parmi les points de l'ensemble d'apprentissage;
- Utilisation d'un algorithme de classe inférieure dans la famille de C-moyennes; HCM->FCM et FCM->PCM;
- etc...

2.3.4. Modélisation des modes de fonctionnement

L'apprentissage ayant été réalisé à partir de données non étiquetées par l'un des algorithmes de classification floue précédentes, il convient, en général, d'interpréter chacune des classes en examinant s'il est possible de lui associer un mode de

fonctionnement du système à surveiller. Ces algorithmes (FCM, PCM, . . .) permettent d'identifier parmi les données recueillies sur le système des prototypes V_k .

Dans le cas où chaque mode de fonctionnement correspond à une seule classe, on pourra déterminer la valeur en toute nouvelle observation X des fonctions d'appartenance par l'équation de degré d'appartenance, selon l'algorithme de classification utilisé pour l'apprentissage des prototypes. Notons que l'utilisation de l'équation (2.41) entraîne:

$$\sum_{k=1}^M u_k(X) = 1 \quad \forall X \quad (2.61)$$

Cela semble une propriété trop forte en diagnostic, notamment lorsque des modes de fonctionnement répertoriés n'est pas exhaustif: il se peut alors que le système se trouve, à un instant donné, éloigné de tous les modes connus, ce qui devrait se traduire par une condition du type :

$$\max_{k=1,M} u_k(X) \approx 0 \quad (2.62)$$

Il est dans ce cas préférable d'adopter la formule «possibiliste modifiée MPCM» pour le calcul des degrés d'appartenance:

$$u_k(X) = [1 + (\|X - V_k\|_A^2 / w_k)^{m/(m-1)}]^{-1} \quad \forall k \quad (2.63)$$

Lorsque plusieurs classes correspondent à un même mode de fonctionnement, il paraît naturel de définir le degré d'appartenance au mode ω_k en fonction des degrés d'appartenance aux classes correspondant à ce mode, en utilisant un opérateur de combinaisons disjonctif. Soit $V_{k,1}, \dots, V_{k,n_k}$ les prototypes caractérisant le mode k et $u_{k,1}, \dots, u_{k,n_k}$ les fonctions d'appartenance correspondantes. On pourra poser, pour une t -conorme \perp :

$$u_k(X) = u_{k,1} \perp \dots \perp u_{k,n_k} \quad (2.64)$$

L'emploi d'autres opérateurs (voir tableau 2.1) tels que la somme bornée pourrait se justifier également:

$$u_k(X) = \min[1, \sum_{l=1}^{n_k} u_{k,l}] \quad (2.65)$$

Une autre approche pour l'apprentissage des fonctions d'appartenance par interpolation est basée sur l'utilisation de réseaux de neurones. [BEN 07] proposent de coïncider les évaluations de degrés d'appartenance avec la sortie d'un réseau de neurones à fonctions de base radiales.

2.3.5. Règles de décision

Il s'agit dans cette étape de définir à quelle classe affecter une nouvelle observation X recueillie à un instant donné sur le système, donc déterminer le mode de fonctionnement du système à cet instant.

Ayant calculé le vecteur Z des degrés d'appartenance aux différentes classes:

$$Z = (u_1(X), \dots, u_M(X))^t \quad (2.66)$$

Le problème est de choisir la classe d'affectation de X . Pour cela il est nécessaire de s'appuyer sur des principes de décision ayant pour base les degrés d'appartenance. Plusieurs règles sont disponibles [DEN 01].

• Règle du maximum d'appartenance

Le principe de maximum d'appartenance consiste à choisir la classe à laquelle le vecteur X a le plus haut degré d'appartenance, notant que les seules actions autorisées sont l'affectation aux classes: $\mathcal{A} = \{\Omega_1, \dots, \Omega_M\}$ où Ω_k désigne l'affectation à la classe ω_k :

$$D(X) = \Omega_k \text{ si } u_k(X) > u_l(X) \quad \forall l \neq k \quad (2.67)$$

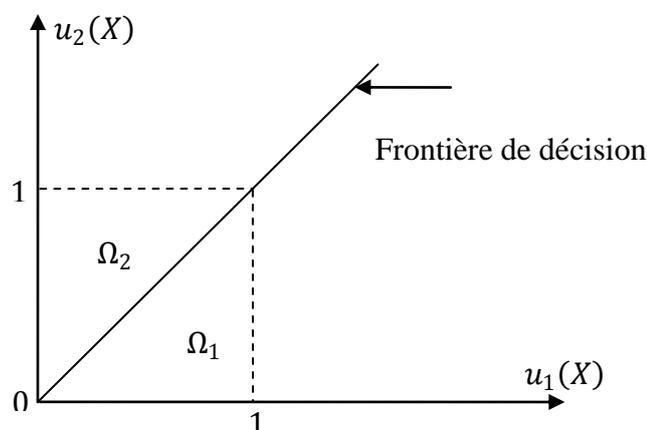


Figure 2.13. Principe de règle du maximum d'appartenance

• Règle de seuillage d'appartenance

La prise en compte du rejet en distance et en ambiguïté nécessite d'introduire deux nouvelles classes: Ω_d classe de rejet en distance et Ω_a classe de du rejet en ambiguïté. Pour cela plusieurs règles peuvent être envisagées, la plus simple est celle du seuillage d'appartenance. Son principe consiste à associer à chaque k un seuil d'appartenance s_k , défini par exemple, de manière à ce qu'une proportion donnée de vecteurs d'apprentissage

aient un degré d'appartenance à la classe k supérieur à s_k . Soit pour un vecteur X donné, l'ensemble $J(X)$ des classes k auxquelles X a un degré d'appartenance supérieur à s_k :

$$J(X) = \{k \in \{1, \dots, M\} / u_k(X) > s_k\} \quad (2.68)$$

La règle de décision incluant les deux options de rejets sera appliquée pour $M + 2$ classes:

$$D(X) = \begin{cases} \Omega_k & \text{si } J(X) = \{k\} \\ \Omega_d & \text{si } J(X) = \emptyset \\ \Omega_a & \text{si } |J(X)| > 1 \end{cases} \quad (2.69)$$

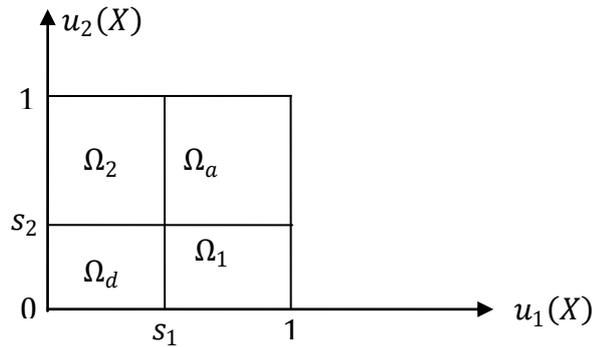


Figure 2.14. Principe de règle de seuillage d'appartenance

• Règle de rapport d'appartenance

L'inconvénient de la règle précédente est le fait que les deux options de rejets sont contrôlées par les mêmes paramètres s_k . La règle de rapport d'appartenance basée sur le seuillage d'appartenance s'appuie sur le rapport:

$$R(X) = u_m(X)/u_p(X) \quad (2.70)$$

Avec

$$u_p(X) = \max_{k \in J(X)} u_k(X)$$

$$u_m(X) = \max_{k \in J(X) \setminus \{p\}} u_k(X)$$

On a évidemment $0 \leq R(X) \leq 1$, et il ya ambiguïté quand $R(X)$ est proche de 1. On pose alors la règle suivante:

$$D(X) = \begin{cases} \Omega_a & \text{si } J(X) > 1 \text{ et } R(X) \geq T_a \\ \Omega_d & \text{si } J(X) = \emptyset \\ \Omega_p & \text{sinon} \end{cases} \quad (2.71)$$

Où T_a : seuil de réglage du rejet en ambiguïté.

• **Règle des degrés de confiance**

Cette règle s'appuie sur la définition de degrés de confiance fonctions de M degrés d'appartenance. Plus précisément, on définit le degré de confiance associé à la classe k pour le vecteur forme X comme:

$$C_k(X) = u_k(X) \prod_{l \neq k} [1 - u_l(X)] \quad (2.72)$$

La quantité $C_k(X)$ est d'autant plus grande que le degré d'appartenance à la classe k est élevé et que les degrés d'appartenance aux autres classes sont faibles. D'autre part, soit:

$$C_0(X) = \prod_{l=1}^M [1 - u_l(X)] \quad (2.73)$$

Cette quantité est d'autant plus grande que les degrés d'appartenance aux classes sont faibles, et traduit donc le caractère « atypique » du vecteur X . Une règle de décision simple, basée sur les degrés de confiance, est donc la suivante:

$$D(X) = \begin{cases} \Omega_d & \text{si } q = 0 \text{ et } C_0(X) > T_{ad} \\ \Omega_k & \text{si } q = k \text{ et } C_k(X) > T_{ad} \\ \Omega_a & \text{sinon} \end{cases} \quad (2.74)$$

Avec, $q = \arg \max_{k \in \{0, \dots, M\}} C_k(X)$

T_{ad} : seuil de réglage du rejet en distance et en ambiguïté.

2.3. Conclusion

Dans ce chapitre nous avons décrit les différentes étapes de l'élaboration d'un système de diagnostic par reconnaissance des formes floue (**RdF floue**). Cette méthode consiste à confronter les données recueillies sur le processus aux informations sur les modes de fonctionnement disponibles dans la base de connaissance.

La méthodologie proposée est basée sur deux phases principales:

- Une phase de classification de données historiques et de détermination des modes de fonctionnement du système (apprentissage hors ligne);
- Une phase de reconnaissance en ligne (en temps réel) du mode de fonctionnement du système (apprentissage en ligne).

Dans la première phase, le vecteur formes est déterminé en fonction des observations caractérisant le système étudié, et ce, en utilisant les méthodes de sélection de paramètres

ou les méthodes d'extraction de paramètres. Les méthodes de classification interviennent par la suite pour déterminer le mode de fonctionnement du système.

À partir de l'étude comparative énoncée précédemment dans le paragraphe 2.3.3, nous choisissons l'algorithme **MPCM** (Modified Possibilistic C-Means) pour la classification des données, dans un contexte d'apprentissage non supervisé, au regard des avantages qu'il présente par rapport aux autres algorithmes (FCM, PCM).

La deuxième phase de la méthodologie adoptée consiste à définir à quelle classe affecter une nouvelle observation recueillie sur le système à un instant donné, ce qui conduit à définir le mode de fonctionnement du système à cet instant (reconnaissance en ligne). Pour ce faire, il est nécessaire de s'appuyer sur les règles de décision ayant pour base les degrés d'appartenance.

À partir de la description avancée dans le paragraphe 2.3.5, correspondant aux différentes règles de décision, nous avons choisi, pour cette phase, la méthode dite du rapport d'appartenance revêtant plus de souplesse par rapport aux autres règles.

L'application de la règle de décision nous permettra de suivre l'évolution du comportement du système et de connaître en temps réel le mode de fonctionnement du processus, y compris le cas de fonctionnement anormal présentant une défaillance éventuelle.

Pour récapituler, nous reprenons ci-après la formulation correspondant à chaque phase sous forme d'algorithme:

Phase 1: Apprentissage hors ligne

Algorithme de MPCM:

- *Paramétrage:*
 - Fixer le nombre de classe M en utilisant le critère de compacité et de séparabilité.
 - Fixer le degré de flou m .
 - Choisir la norme A .
 - Choisir le seuil d'arrêt ϵ et le nombre maximal des itérations T .
- *Initialisations :*
 - Initialiser le compteur de boucle $t \leftarrow 0$.
 - Initialiser la partition en utilisant l'algorithme de FCM
 - Calculer les w_k à l'aide de la formule (2.55)
- *Itérations:*

Répéter

$t \leftarrow t + 1$

Calcul de la matrice de partition U_t par la formule (2.58)

Calculer les prototypes V_t à l'aide de la formule (2.57)

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \epsilon$

Représentation graphique des données

Réduction de l'espace de représentation à 2D via la méthode ACP

Phase 2: Reconnaissance en ligne

Définition des fonctions d'appartenance $u_k(X)$ pour $k = 1, \dots, M$, par la formule (2.63)

Appliquer la règle de rapport d'appartenance $D(X)$, en utilisant la formule (2.71)

Déduire le mode de fonctionnement du système.

Sur la base de la formulation adoptée, nous avons développé un programme informatique en **MATLAB7** qui sera appliqué dans le chapitre 3 pour le diagnostic des défaillances de la station de production d'eau potable de TAKSEBT située dans la wilaya de TIZI OUZOU.

Application de la méthode a la
station de production d'eau potable
de TAKSEBT

Chapitre 3 :

Application de la méthode a la station de production d'eau potable de TAKSEBT

(Identification des états fonctionnels)

3.1. Introduction

Après avoir présenté la formulation générale relative à la méthode de reconnaissance des formes floue, nous essaierons dans le présent chapitre de l'appliquer pour le diagnostic de la station de production d'eau potable de TAKSEBT.

Pour ce faire, nous avons développé un programme de calcul en MATLAB7, en se référant à l'algorithme récapitulé dans le chapitre précédent, que nous avons appliqué sur la base de données historique renfermant les caractéristiques de l'eau traitée le long de la chaîne de production et correspondant à une année de fonctionnement de la station (2010). Le but de notre application consiste à faire un apprentissage hors ligne du comportement de la station en identifiant ses différents modes de fonctionnement. Puis, la méthode sera appliquée pour faire la reconnaissance en ligne de son fonctionnement et déceler en temps réel tout défaut pouvant surgir, découlant d'un mode de fonctionnement anormal de la station.

D'abord, nous présentons les caractéristiques générales de la station de TAKSEBT de production d'eau potable. Nous exposerons, par la suite, les différentes phases de production ainsi que les aspects fonctionnels de la station par rapport à la concentration des réactifs chimiques, la turbidité de l'eau brute ainsi que les autres caractéristiques de l'eau traitée (température, pH).

Nous terminerons ce chapitre par l'illustration et l'interprétation des résultats de notre application.

3.2. Description de la station

Située dans la wilaya de TIZI OUZOU, la station de production d'eau potable de TAKSEBT a été mise en service en Mai 2007. Elle s'étend sur une superficie de **34 hectares**, et elle a été dimensionnée pour traiter un débit maximal d'eau de **616 000 m³/j**.

L'eau qui alimente la station de traitement arrive de façon gravitaire sur une distance de 8 km du barrage TAKSEBT qui est alimenté à son tour par l'oued AISSI et de l'oued BOUGDOURA.

La station est conçue pour l'alimentation en eau potable des communes suivantes : FREHA, AZAZGA, DRAA BEN KHEDDA, centre wilaya de TIZI OUZOU et le grand ALGER. Le transport se fera de façon gravitaire depuis la station de traitement jusqu'au réservoir d'eau traitée de DRAA BEN KHEDDA, puis l'eau continue à être transférée à travers les conduites de fonte et les tunnels jusqu'au réservoir de BOUDOUAOU. Tout au long du transfert, des piquages sont opérés pour alimenter les villes de TIZI OUZOU et DRAA BEN KHEDDA.

3.2.1. Capacité de la station

La production nominale de la station de traitement de TAKSEBT est de 605 000 m³/j (7000 l/s) basée sur un approvisionnement en eau brute de 616 000 m³/j [DEG 08].

• Débit d'eau brute :	616 000 m ³ /j
• Volume des boues extraites des clarificateurs :	7 400 m ³ /j
• Volume des boues extraites des filtres :	3 600 m ³ /j
• Production d'eau traitée :	605 000 m ³ /j

La capacité hydraulique nominale de la station est de 647 000 m³/j, prenant en compte un débit recyclé de 5% du débit d'eau brute.

Les variations de débits d'eau traitée prévues sont de :

• Débit minimum :	202 000 m ³ /j
• Débit moyen :	474 000 m ³ /j
• Débit maximum (nominale) :	605 000 m ³ /j

3.2.2. Qualité de l'eau à l'entrée de la station :

L'eau brute alimentant le barrage de TAKSEBT provient de l'oued AISSI et de l'oued BOUGDOURA. La conception de l'usine de traitement est basée sur les valeurs du tableau suivant [DEG 08].

Paramètres	Unité	Valeurs contractuelles		
		Min	Max	Typique
pH		7.00	9.00	8.00
Couleur	Hazen	5	25	6
Turbidité	NTU	1	100	5
Conductivité	Us/cm	300	800	500
Température	C	10	30	18
Ammoniac	Mg/I N	0.01	0.2	0.05
Nitrite	Mg/I N	<0.001	0.05	0.002
Nitrate	Mg/I N	0.5	4	1
Matières organique	Mg/I O	2.5	10	3.5
Alcalinité	Mg/I CaCO ₃	100	250	160
Dureté total	Mg/I CaCO ₃	100	350	200
Calcium	Mg/I ca	20	70	40
Magnésium	Mg/I Mg	15	60	24
Sodium	Mg/I Na	5	60	15
Chlorure	Mg/I Cl	10	70	30
Sulfate	Mg/I SO ₂	20	100	40
Orthophosphate	Mg/I P	<0.01	0.2	0.05
Fer (total)	Mg/I Fe	0.05	5	0.15
Manganèse (total)	Mg/I Mn	<0.01	0.1	0.02
Silice réactif	Mg/I SiO ₂	0.1	10	5
Oxygène dissout	Mg/I O	4.0	10.0	8.0
Demande biochimique en oxygène	Mg/I O	0.2	10.0	1.0
Demande chimique en oxygène	Mg/I O	<10	60	20
Coliformes totaux	MPN/100ml	10	10 000	200
E. coli	MPN/100ml	5	5 000	100
Chlorophylle a	Mg/m ³	<5	40	15

Tableau 3.1. Valeurs contractuelles relatives aux caractéristiques de l'eau produite

3.2.3. Qualité de l'eau à la sortie de la station :

La station de traitement est conçue pour pouvoir assurer une alimentation fiable et continue en eau potable, exempte d'organismes pathogènes. Dans les conditions de qualité de l'eau contractuelles et d'une exploitation normale, la qualité finale de l'eau après traitement doit être conforme aux normes suivantes 100 % du temps [DEG 08].

- Turbidité (avant injection de chaux) inférieure à 1,0 NTU
- Goût et odeur acceptables pour le consommateur
- Couleur inférieure à 5° Hazen
- Aluminium (Al) inférieur à 0,2 mg/l
- Fer (Fe) inférieur à 0,3 mg/l
- Manganèse (Mn) inférieur à 0,1 mg/l
- pH 6,5 à 8,5
- E coli ou bactérie thermotolérante néant sur tout échantillon de 100 ml
- Total bactéries coliformes néant sur tout échantillon de 100 ml

En ce qui concerne les autres paramètres individuels, ils seront inférieurs aux valeurs désirables les plus élevées recommandées par les normes les plus récentes de l'OMS pour les eaux de boisson.

3.2.4. Exploitation de la station

3.2.4.1. Etapes du traitement de l'eau

La station de TAKSEBT est composée de deux chaînes de traitement identiques. L'eau traitée au niveau de la station passe par plusieurs ouvrages avant d'arriver au bout de la station (réservoir de stockage). Les différentes étapes de traitement sont:

- La dissipation, le mélange et la répartition;
- La coagulation et floculation;
- La filtration;
- La désinfection et le stockage (réservoir).

3.2.4.1.1. Dissipation, mélange et répartition :

L'arrivée d'eau brute à la station de TAKSEBT se fait dans la chambre de dissipation. L'eau surnageant des dessableurs est également retournée dans la chambre de dissipation. Les déversoirs en sortie de la chambre assurent un niveau minimum, donc un volume tampon capable de tranquilliser l'arrivée d'eau brute. Si nécessaire, il est possible de procéder à une préchloration dans l'ouvrage, principalement dans le but de limiter la présence d'organismes (algues, bactéries, plancton) susceptibles de proliférer dans les filières de traitement [DEG 08].

La chambre d'arrivée possède un volume de 430 m³ assurant un temps de rétention de 60 secondes au débit d'eau brute maximal de 616 000 m³/j.

L'injection de chlore, de sulfate d'aluminium, d'acide sulfurique, de permanganate de potassium et de charbon actif en poudre s'effectue dans cette chambre. Le mélange des produits chimiques est réalisé dans les trois déversoirs vers la chambre de mélange.

Un trop-plein est prévu dans la chambre d'arrivée pour dévier le débit excédentaire. Ce trop-plein est calé à l'élévation 165,55 m et la lame d'eau est de 22 cm au débit maximal de 647 000 m³/j. Certaines caractéristiques de l'eau brute (conductivité, pH et turbidité) sont mesurées en permanence.

L'eau brute passe ensuite à travers la chambre de mélange. Cet ouvrage assure un temps de contact suffisant pour assurer le mélange homogène des réactifs.

Les réactifs remplissent les fonctions suivantes :

- Permanganate de potassium : limiter la présence de manganèse et/ou contrôler la charge biologique.
- Charbon actif en poudre : contrôle du goût et des odeurs.
- Sulfate d'alumine : coagulant pour faciliter la clarification dans les décanteurs Pulsatube.
- Acide sulfurique : ajustement du pH pour optimiser la coagulation.

L'ouvrage de répartition permet deux choix d'exploitations :

Une répartition équilibrée du débit vers les décanteurs Pulsatube (2 filières de 4 décanteurs chacune).

Une répartition du débit vers les ouvrages de by-pass des décanteurs (1 canal pour chaque filière). Lorsque les canaux de by-pass sont utilisés, un polymère y est injecté, de manière à assurer une floculation directement sur les filtres.

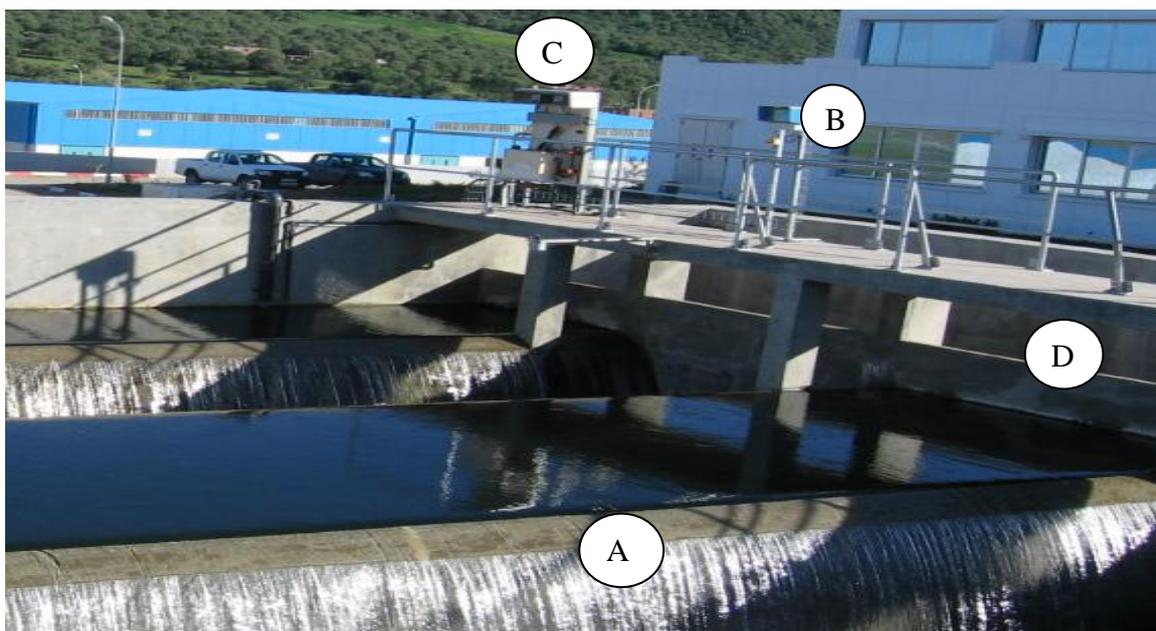


Figure 3.1. Ouvrage de répartition d'eau

Indice	Description
A	Déversoirs d'arrivée d'eau
B	Mesure de niveau ultrasonique
C	Analyseurs de turbidité, conductivité et pH
D	Déversoir de trop-plein

3.2.4.1.2. La coagulation & floculation

La turbidité de l'eau a pour origine la présence de matières en suspension (argile, limons, particules fibreuses, particules organiques colloïdales, plancton, organismes microscopiques) qui donne un aspect trouble à l'eau.

L'un des objectifs majeurs du traitement de l'eau, c'est de la clarifier c'est-à-dire éliminer plus ou moins complètement ces matières non dissoutes (MES et colloïdes), la décantation en assure en partie l'élimination, mais ce procédé lorsqu'il est utilisé seul, ne convient que pour l'élimination des particules les plus denses (sables, par exemple). Les particules plus fines (limons, argiles, poussières) nécessitent des vitesses d'eau quasi nulles pour pouvoir être séparées par simple décantation et doivent donc subir l'étape de la coagulation-floculation.

C'est une étape qui pose une problématique complexe et sensible, notamment lors du traitement d'une eau de surface (rivière, retenue). L'eau à traiter peut alors subir des

variations de composition chimique ou physique très importantes suivant la climatologie du moment.

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

Un mauvais contrôle de ce procédé peut entraîner une augmentation importante des coûts de fonctionnement, en effet, la production d'un floc trop petit ou trop léger entraîne une décantation insuffisante : lorsque les eaux arrivent sur les filtres, elles contiennent une grande quantité de particules de floc, qui encrassent rapidement ces filtres, ce qui nécessite des lavages fréquents et engendre le non-respect des objectifs de qualité en sortie. Lorsque le floc est fragile, il se brise en petites particules qui peuvent traverser les filtres et altérer la qualité de l'eau produite (les risques sanitaires ne sont pas directement liés à la présence des particules en suspension mais aux bactéries, kystes, parasites et surtout virus qui s'y fixent en se protégeant des désinfectants). On voit donc toute l'influence de cette étape sur les opérations de décantation et de filtration ultérieures.

En revanche, un contrôle efficace peut réduire les coûts de main d'œuvre et des réactifs et améliorer la conformité de la qualité de l'eau traitée.

Le contrôle de cette opération est donc essentiel pour trois raisons : la maîtrise de la qualité de l'eau traitée en sortie (diminution de la turbidité), le contrôle du coagulant résiduel en sortie (réglementation de plus en plus stricte de la présence de coagulant résiduel dans l'eau traitée), et la diminution des contraintes et des coûts de fonctionnement [HER 06].

Actuellement, pour déterminer la dose optimale de coagulant on procède à une analyse chimique effectuée au laboratoire appelée << Jar-test >>. Sa conduite est manuelle (nécessité d'un technicien de laboratoire) et requiert des analyses longues (en moyenne une heure pour effectuer un Jar-test) et coûteuses.

Un déficit intéressant à relever concernant cette étape et pour le traitement des eaux en général serait de maîtriser au mieux la concentration du coagulant à introduire, en fonction des caractéristiques de l'eau brute à traiter, en se référant aux données historiques relatives au fonctionnement de l'usine.

Principe de la coagulation

C'est le processus qui vise, en premier lieu, la déstabilisation d'une suspension colloïdale par addition de réactifs coagulants, essentiellement de sels métalliques (sels de

fer et/ou d'aluminium) dont l'hydrolyse libère des composés intermédiaires qui neutralisent les charges des colloïdes, et en second lieu, l'agrégation des particules en petits amas, ou flocons, sous l'action du mouvement brownien.

L'autre, la floculation, est le processus d'agglomération des particules solides fines (et des colloïdes déstabilisées) en flocs d'abord très fins, puis de plus en plus volumineux. Les floculants sont en général des polymères minéraux (silices activée, par exemple), ou organique d'origine naturelle (alginate), ou de synthèse (polyacrylamides).

L'opération de coagulation-floculation a donc pour but la croissance des particules (qui sont essentiellement colloïdales) par la déstabilisation des particules en suspension puis la formation de flocs par absorption et agrégation. Les flocs ainsi formés seront décantés et filtrés par la suite.

Dans la station de TAKSEBT, le coagulant utilisé est le sulfate d'alumine, il est donc introduit dans l'eau afin de neutraliser les charges négatives qui sont à l'origine du maintien en suspension stable.

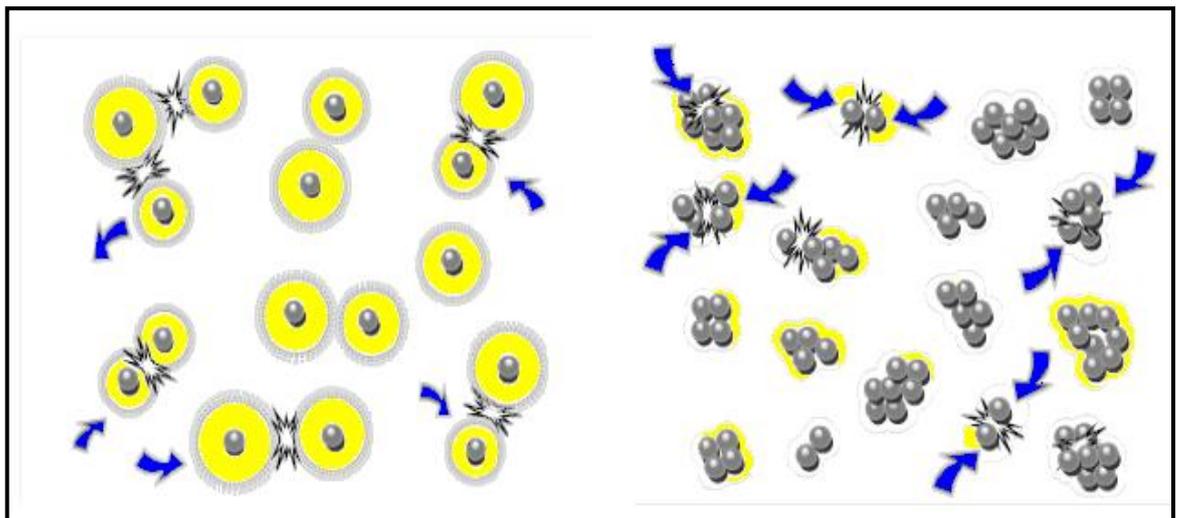


Figure 3.2. Eau brute additionnée de coagulant

Facteurs influençant la coagulation-floculation:

- La température

La température joue un rôle important. En effet, une température basse entraînant une augmentation de la viscosité de l'eau, crée une série de difficultés dans le déroulement du processus ; la coagulation et la décantation du floc se trouvent ralenties et la plage du pH optimal diminue. Pour éviter ces difficultés, une solution consiste à changer de coagulant en fonction des saisons.

- Le pH

Le pH a une influence primordiale sur la coagulation. Il est d'ailleurs important de remarquer que l'ajout d'un coagulant modifie souvent le pH de l'eau. Cette variation est à prendre en compte afin de ne pas sortir de la plage de pH de précipitation du coagulant. La plage du pH optimal est la plage à l'intérieur de laquelle la coagulation sera suffisamment rapide. En effet, une coagulation réalisée à un pH non optimale peut entraîner une augmentation significative du temps de coagulation. En général, le temps de coagulation est compris entre 15 secondes et 3 minutes. Le pH a également une influence sur l'élimination des matières organiques.

- La turbidité

La turbidité est elle aussi, un paramètre influant sur le bon déroulement de la coagulation. Dans une certaine plage de turbidité, l'augmentation de la concentration des particules doit être suivie d'une augmentation de la dose du coagulant.

Quand la turbidité de l'eau est trop faible, on peut augmenter la concentration en particules par addition d'argile par exemple. Dans le cas de fortes pluies, l'augmentation de MES favorise une meilleure décantation. Enfin, pour grossir et alourdir le floc, on ajoute un adjuvant de floculation.

3.2.4.1.3. La décantation

L'objectif de la décantation est de séparer les particules floculées de l'eau clarifiée. Les particules colloïdales ne peuvent être décantées efficacement que si elles entrent en contact entre elles pour former des floccs de plus grande taille.

Les contacts entre particules sont d'autant plus fréquents que leur concentration est grande dans l'eau. C'est le principe de base des décanteurs à lit de boues, dont fait partie le Pulsatube.

Une partie des MES décantée est conservée en fond d'ouvrage, formant un lit de boue.

L'eau entrante traverse ce lit de boue de bas en haut. Les floccs nouvellement formés en entrée du décanteur passent à travers le lit de boue, entrent en contact avec les floccs conservés et s'y agrègent.

Pour assurer le meilleur contact, le lit de boue doit rester en expansion. Il occupe un volume apparent variable selon sa densité et la vitesse de l'eau. Il ne doit pas se tasser et être relativement homogène (pas de passage préférentiel du flux).

Les décanteurs sont dimensionnés pour accepter un débit maximal théorique unitaire de 4500 m³/h, correspondant à une vitesse ascensionnelle de 7,55 m³/m².h.

L'exploitant doit donc veiller à ce que le nombre de décanteur en service soit supérieur au débit total entrant divisé par 4500 m³/h.

En pratique, le débit maximal acceptable sur les décanteurs Pulsatube dépend fortement des caractéristiques de l'eau et du dosage des réactifs, et des valeurs supérieures à 4500 m³/h peuvent éventuellement être acceptables.

En tout cas, à débit élevé, l'exploitant portera une attention particulière à l'évolution des mesures de MES et turbidité dans l'eau décantée. Si cette évolution est négative et que la filtration, en aval, n'est pas en mesure de limiter la détérioration de la qualité de l'eau, alors l'exploitant devra se coordonner avec l'exploitant de la station de pompage des eaux brutes pour réduire le débit entrant.

L'ajout de polymère en amont des décanteurs, sur les déversoirs de l'ouvrage de répartition permet la concentration des MES en floccs plus facilement décantables.

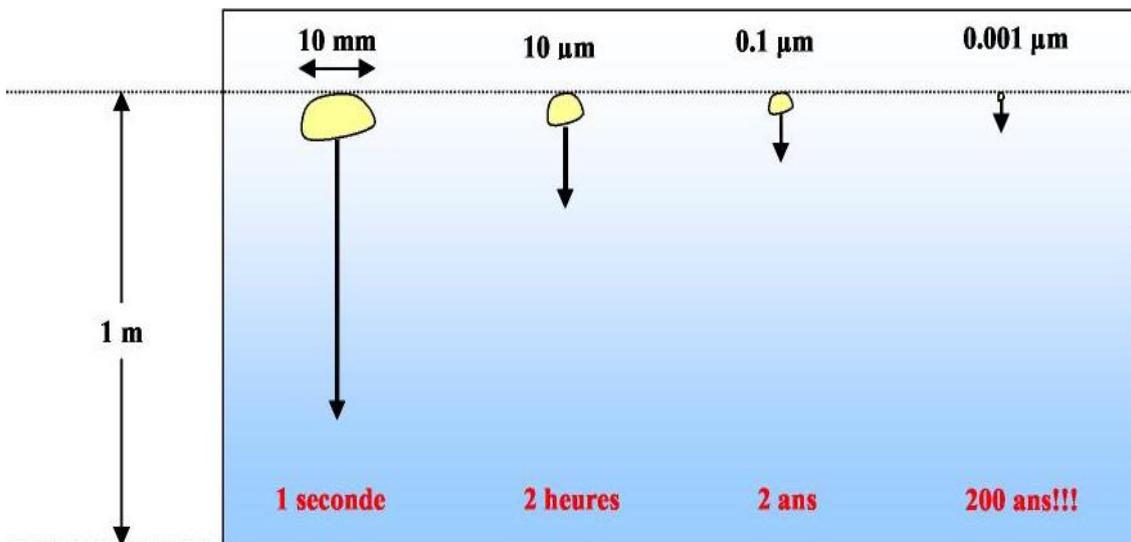
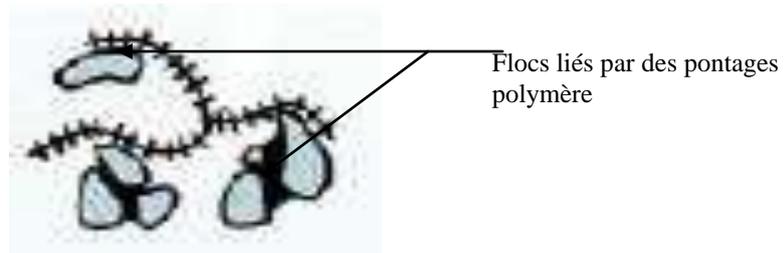


Figure 3.3. Schéma de la décantation naturelle



Si les décanteurs sont utilisés conformément aux recommandations techniques arrêtées, avec un débit entrant maximum de 647 000 m³/jour, ils fourniront une eau répondant à titre constant aux valeurs ci-après :

- Turbidité : 5 NTU au plus
- Solides en suspension : 5 mg/l au plus
- Aluminium sous forme d'Al : 0,4 mg/l au plus

3.2.4.1.4. La filtration

La filtration est le processus qui vient juste après la décantation. L'eau admise à ce niveau est filtrée de façon gravitaire à travers un lit de sable pour éliminer les matières en suspension.

Principales caractéristiques des filtres:

- Grande hauteur d'eau au-dessus du lit filtrant, dans la plupart des cas, égale à 1,20 m.
- Hauteur de matériau filtrant homogène comprise entre 0,8 et 1,5 m
- Une taille effective du matériau filtrant, en général de 0,95 mm ou 1,35 mm (fourchette extrême: 0,7 mm et 2 mm).
- Un lavage simultané à l'air et à l'eau accompagné d'un balayage en surface à l'eau décantée, suivi d'un rinçage à l'eau, sans mise en expansion du lit filtrant, et toujours avec balayage en surface. Ce balayage permet d'évacuer, plus rapidement les impuretés à l'égout, ce qui réduit la durée du lavage.



Figure 3.4. Filtres de la station

Fonctionnement en filtration :

En filtration, l'eau est admise dans le filtre depuis le canal d'eau décantée. Un déversoir dénoyé permet l'équirépartition des débits entre les filtres en service. L'eau est ensuite filtrée de façon gravitaire à travers un matériau filtrant (sable).

Le matériau filtrant est de composition et de granulométrie homogène. L'eau filtrée est ensuite collectée par des buselures traversant la dalle planché qui supporte les matériaux filtrants.

Des vannes régulantent augmentent ou diminuent le débit de manière à garder un niveau d'eau stable au dessus du filtre, quelque soit le niveau de colmatage. L'eau est ensuite dirigée vers le canal d'eau filtrée.

Fonctionnement en lavage :

La perte de charge au travers du filtre est mesurée en permanence et indique le niveau de colmatage du filtre.

Lorsque le filtre est colmaté, une demande de lavage automatique est générée. Elle consiste principalement en l'injection d'air et d'eau au travers du filtre, à contre-courant. L'eau permet d'entraîner les particules capturées par le sable. L'air permet de fluidiser et de brasser la couche de sable. Un matelas d'air est formé sous le plancher de manière à distribuer uniformément l'air sur toutes les buselures.

L'eau de lavage est fournie par des pompes dédiées, et l'air de lavage par des surpresseurs.

Matériel filtrant

Dalle béton

Matelas d'air

Eau de lavage

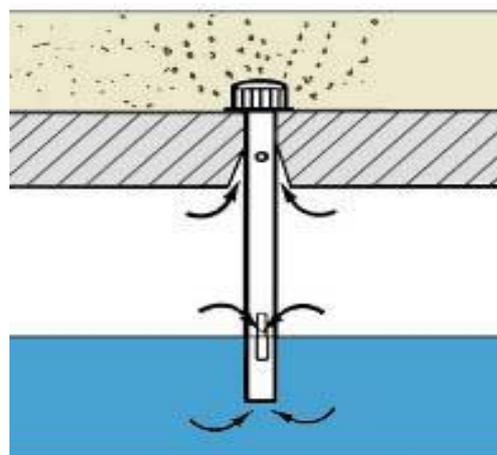


Figure 3.5. Fonctionnement des BUSELURES lors de la phase de lavage air+eau

Caractéristiques de l'eau :

Ces valeurs sont données à titre indicatif, pour un fonctionnement nominal dans le cadre de la qualité de l'eau brute définie au projet.

L'eau entrante est normalement de l'eau décantée. La qualité d'eau prévue en sortie des décanteurs Pulsatube est la suivante :

- Turbidité : 5 NTU au plus
- Solides en suspension : 5 mg/l au plus

Dans ces conditions, les filtres sont conçus pour délivrer de l'eau filtrée avec la qualité prévue pour le projet, en terme de turbidité et de MES.

3.2.4.1.5. Désinfection et stockage de l'eau traitée :

La plupart des eaux, qu'elles aient subi ou non un traitement préalable et, même si elles sont parfaitement limpides, se trouvent souvent contaminées par des microbes dangereux pour l'organisme humain.

La désinfection finale de l'eau traitée est faite dans des cuves de contact, après injection de chlore.

Le chlore, par sa grande efficacité à l'état de traces, et par sa facilité d'emploi, est le réactif le plus utilisé pour assurer la désinfection de l'eau. L'action microbicide, à faible dose, s'explique par la destruction des diastases indispensables à la vie des germes microbiens.

On introduit dans l'eau une dose de chlore légèrement inférieure au "test", si la température est inférieure à 10° et légèrement supérieure au « test » si la température est supérieure à 15° (le chlore est consommé par la lumière et la chaleur).

L'action du chlore, pour être optimale, nécessite un réservoir de contact permettant

- Un temps de contact suffisamment long
- Un flux piston : la dose de chlore initiale est appliqué dans la zone où le nombre d'organismes à éliminer est le plus important
- Un flux homogène, sans zone morte ni court-circuit.

La sortie des cuves de contact, vers les réservoirs d'eau traitée, se fait par-dessus un déversoir. Par conséquent, le niveau d'eau dans les cuves de contact en service est quasiment constant. Le lait de chaux est injecté au dessus du déversoir.

Réservoir d'eau traitée et Chambre de sortie :

Les réservoirs d'eau traitée jouent le rôle de bassin de stockage, permettant de conserver une réserve de production de 1,5 heure au débit nominal de production (605 000 m³/j).

Les réservoirs débouchent dans une chambre de sortie. La chambre de sortie assure la distribution de l'eau vers les conduites de sortie d'eau traitée.

Les pompes d'eau de service, ainsi que les pompes de dilution de chaux sont alimentées depuis cette chambre.

Caractéristiques de l'eau :

L'eau entrante est de l'eau filtrée. L'eau de sortie, après chloration et chaulage, doit respecter les critères de qualité, dans la mesure où la qualité de l'eau brute est dans le cadre des valeurs prises en compte pour la conception et le dimensionnement de la station et des normes en vigueur.

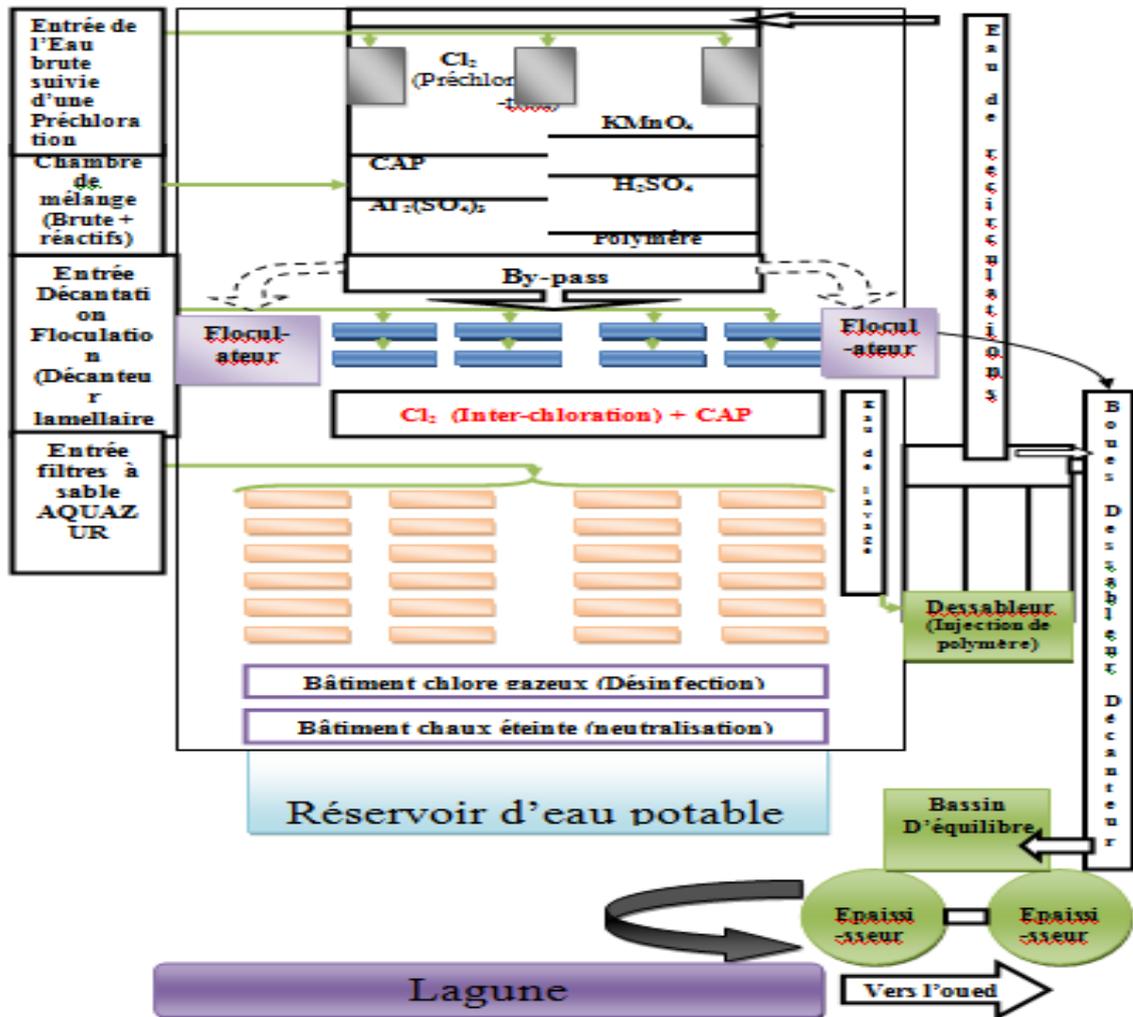


Figure 3.6. Schéma Général de l'usine de traitement d'eau potable de la station TAKSEBT

3.2.5. Aspects fonctionnels de la station et besoins de maintenance

Concernant le fonctionnement de la station de production d'eau potable de TAKSEBT, on constate une forte dépendance aux phénomènes saisonniers. En effet, en période de pluie nous observons une augmentation de la turbidité ce qui nécessite l'utilisation de quantités de plus en plus importantes de réactifs coagulants (Sulfate d'alumine) pour procurer une meilleure formation de floccs et engendrer conséquemment une décantation plus rapide dans la station.

Dans une telle situation, il peut y avoir une augmentation de la turbidité à la sortie des décanteurs (avant les filtres). Ce comportement que l'on pourrait qualifier d'anormal est dû à l'accumulation de boues dans les décanteurs et l'eau sort plus sale qu'elle ne rentre. Cela pourrait même provoquer le blocage du système d'aspiration de boues. La maintenance des décanteurs dans un cas pareil devient indispensable.

Pendant l'été, la coagulation & floculation devient moins efficace, la décantation et l'extraction de solides sont de plus en plus difficiles à effectuer. Le dosage du coagulant doit être précis pour permettre la formation de floccs. Durant la même période, lorsque la température et le pH se trouvent élevés ($\text{pH} > 8,4$), on peut assister au phénomène de formation d'algues pouvant se répercuter négativement sur le rendement des filtres.

3.3. Résultats liés au diagnostic de la station

Pour la caractérisation de la station, la qualité et la quantité d'information dont le gestionnaire de la station dispose sont fondamentales. L'ensemble des données sont des mesures qui sont obtenues par l'analyse de prélèvements journaliers.

Une base de données liée au fonctionnement de la station portant sur les années 2010 et 2011 a été mise à notre disposition, elle comprend un grand nombre de caractéristiques de l'eau traitée (turbidité, pH, température, taux du coagulant, taux de traitement en chlore, matières en suspension, conductivité,...). Toutefois, pour des raisons d'efficacité, et suite à la consultation des responsables (expert) de la station, nous avons recouru à la réduction du nombre de paramètres à étudier pour diagnostiquer le comportement de la station en prenant les plus significatifs qui sont au nombre de cinq (05), à savoir:

- La turbidité d'eau brute (entrée des décanteurs);
- La turbidité d'eau à la sortie des décanteurs;
- Le pH;

- La température de l'eau traitée;
- Le taux du coagulant (sulfate d'alumine).

Cette démarche a été arrêtée en coordination avec le groupe de recherche activant au niveau du département du génie de l'environnement à l'université de BOUMERDES, qui travaille sur l'aspect hydraulique lié au fonctionnement de ladite station.

Le programme de calcul que nous avons développé en MATLAB7, en se référant à l'algorithme général évoqué dans le chapitre précédent, a été appliqué dans un premier lieu pour faire un apprentissage hors ligne sur le fonctionnement de la station en prenant les données mesurées quotidiennement durant l'année 2010 (phase de classification). Par la suite, nous aurons à tester notre programme informatique pour faire la classification de nouvelles observations en faisant application de la règle de décision dite du rapport d'appartenance (phase 2) et ce, avant d'aborder la reconnaissance en ligne du fonctionnement de la station en tenant compte des données réelles correspondant à l'année 2011.

3.3.1. Phase d'apprentissage hors ligne (classification des données)

L'évolution des cinq paramètres étudiés durant l'année 2010 est illustrée à travers les figures 3.7 à 3.11.

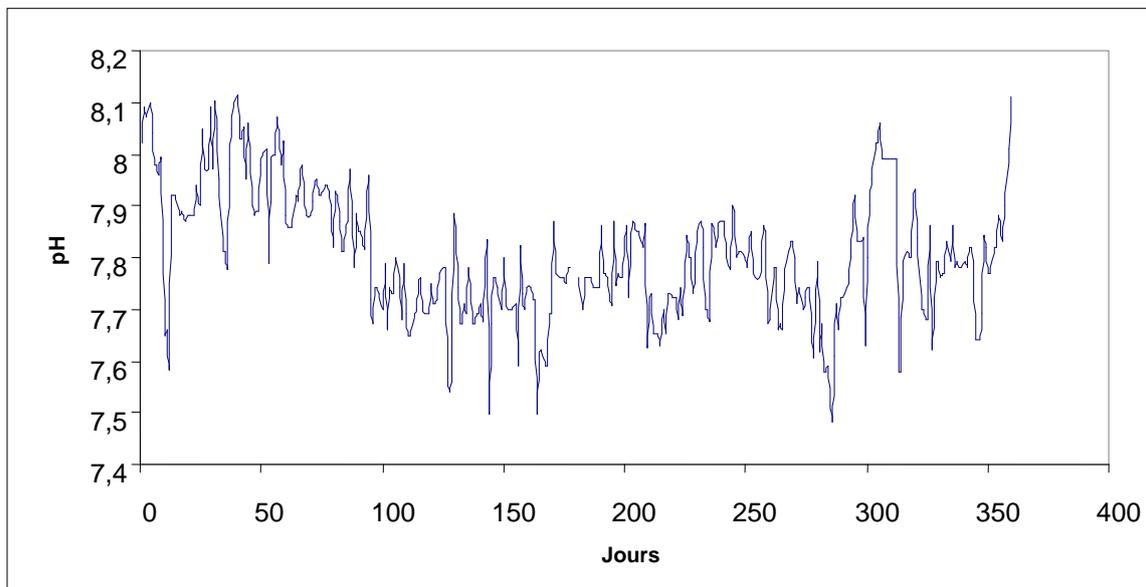


Figure 3.7. Evolution du pH

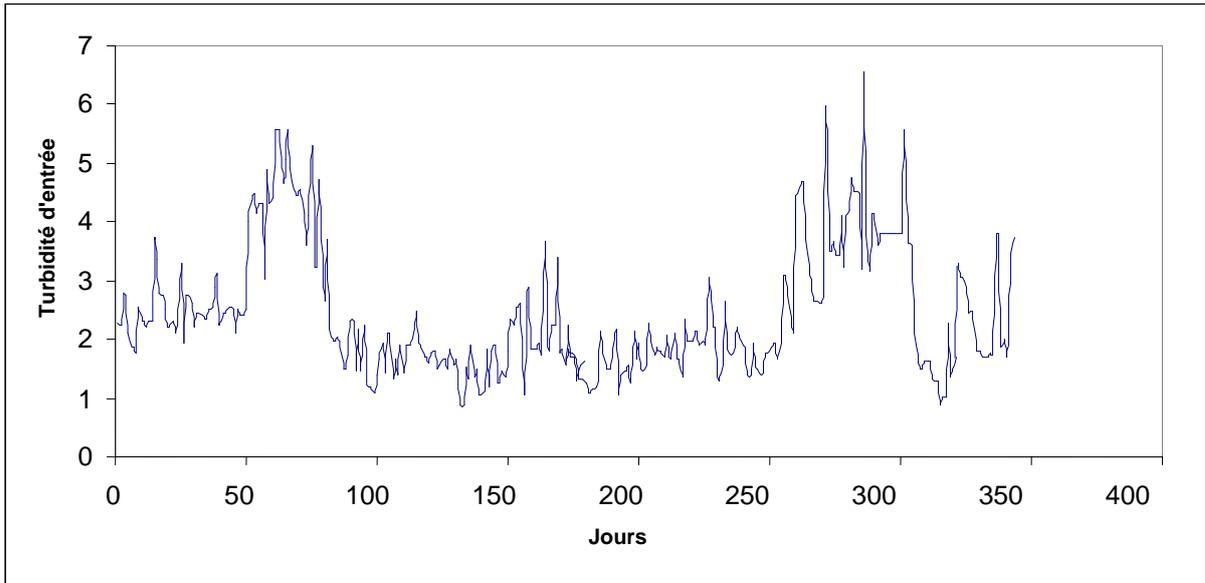


Figure 3.8. Evolution de la turbidité d'entrée (NTU)

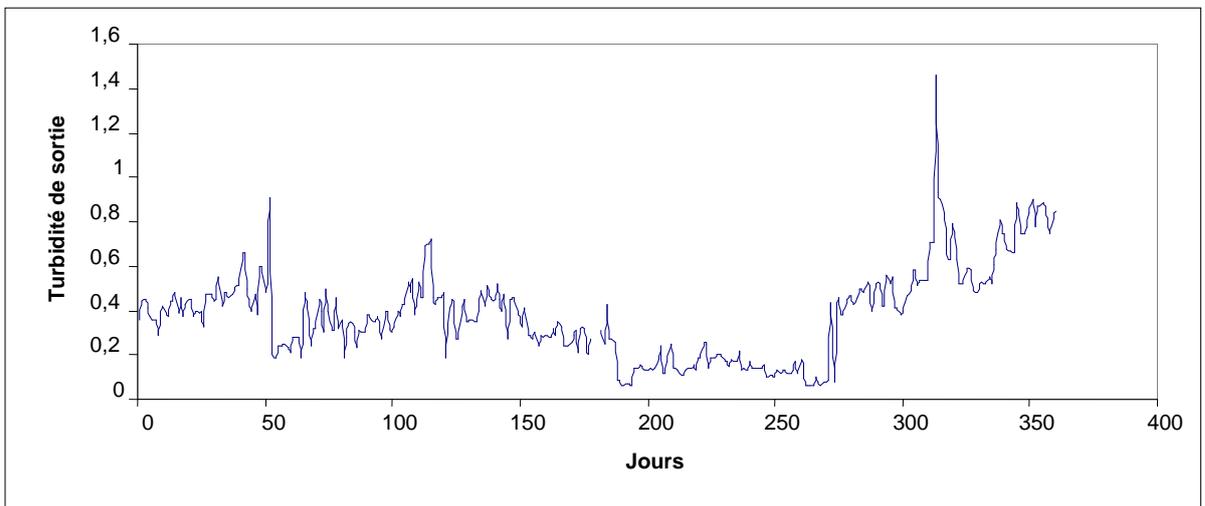


Figure 3.9. Evolution de la turbidité de sortie (NTU)

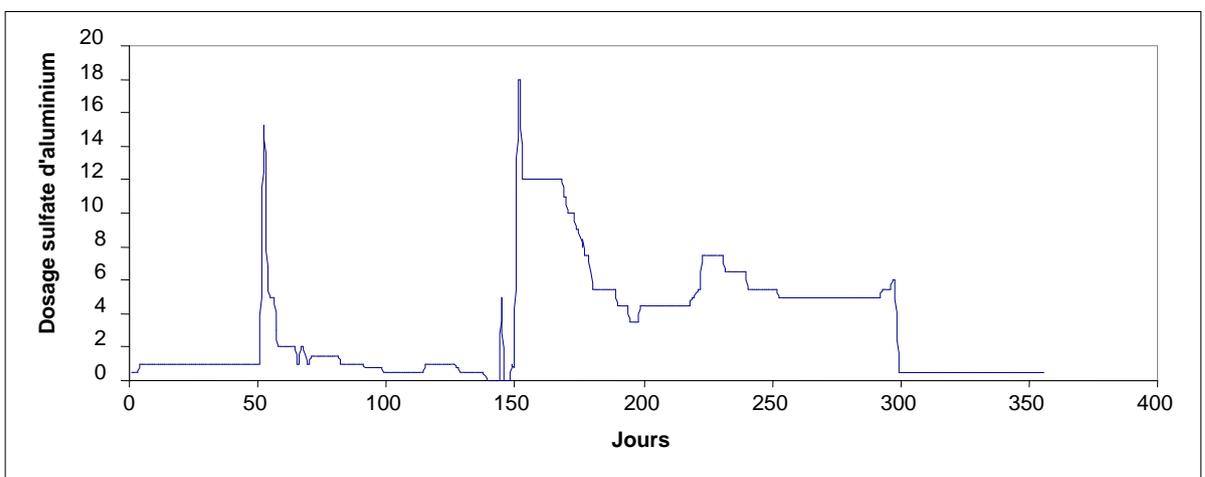


Figure 3.10. Evolution du taux du coagulant (sulfate d'alumine)

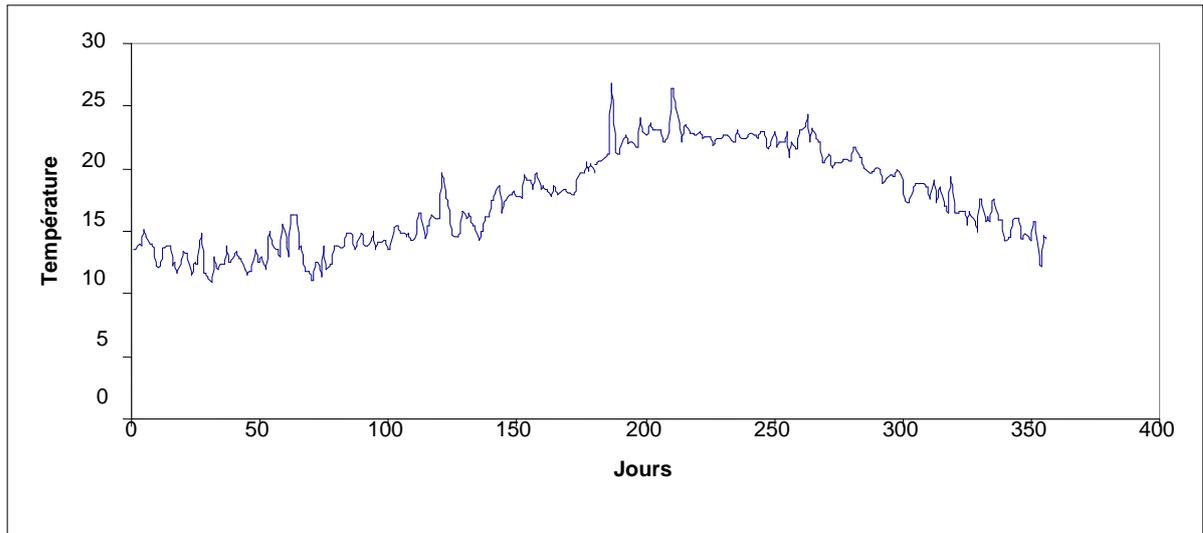


Figure 3.11. Evolution de la température

Les résultats du programme illustrés graphiquement via la figure 3.12 font ressortir quatre classes représentant l'ensemble des observations prises sur l'année 2010. Ces classes ont été interprétées à l'aide des profils représentés dans la figure 3.13. Elles ont été associées aux quatre situations présentées dans le tableau 3.2.

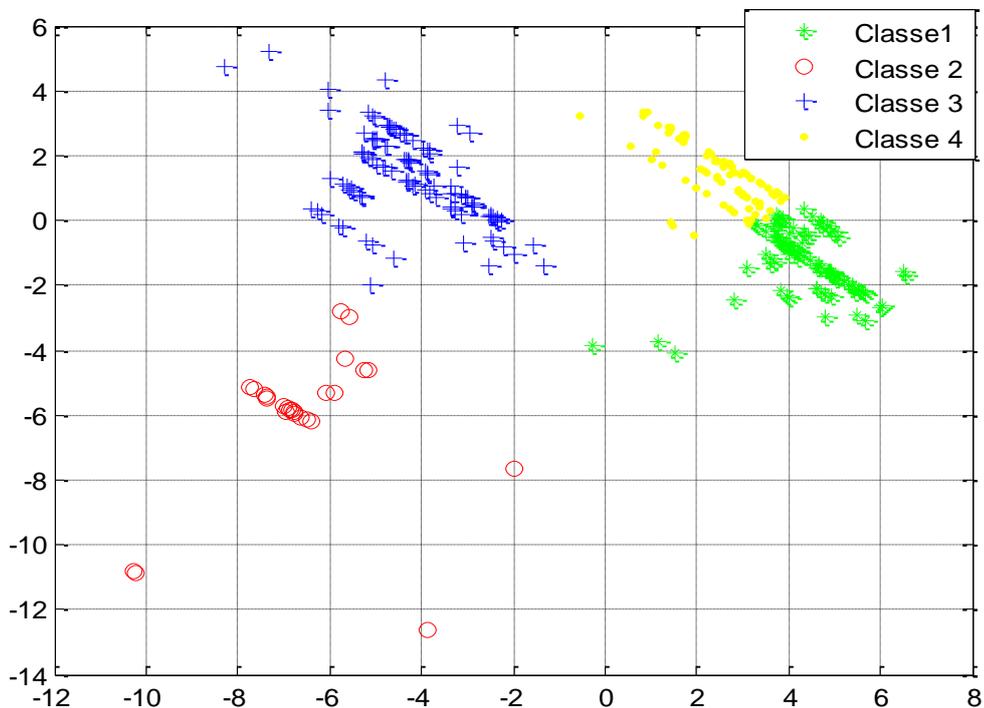


Figure 3.12. Résultats du programme (classification des données)

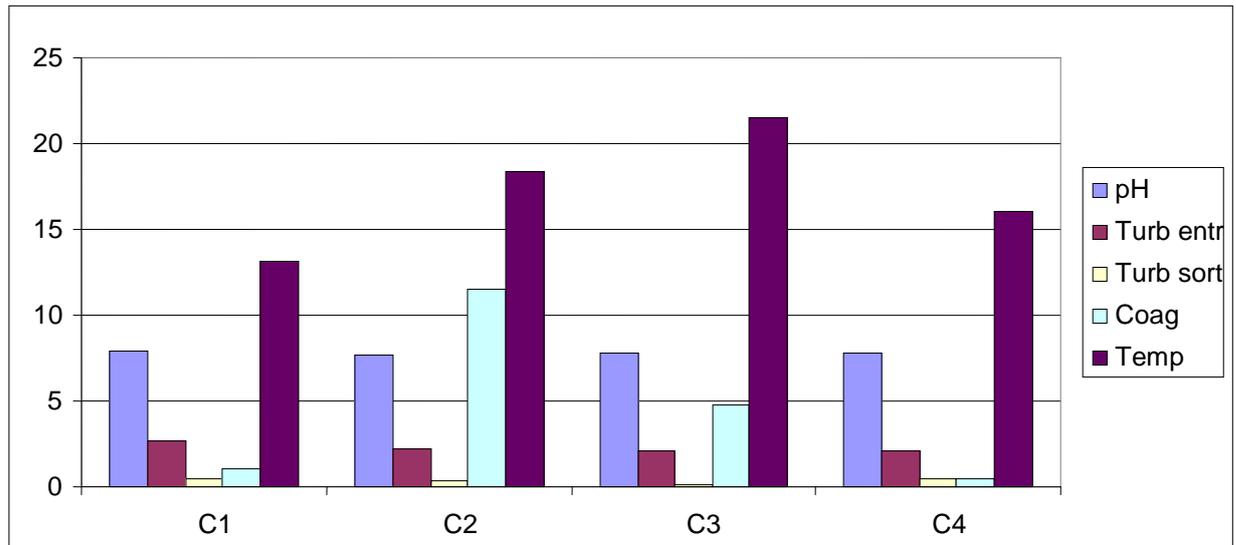


Figure 3.13. Profils de classes

Selon les résultats d'apprentissage hors ligne, nous constatons l'existence de quatre modes de fonctionnement de la station correspondant aux quatre classes révélées. Avec l'apport de l'expert, nous avons essayé d'interpréter les quatre situations ressorties suivant le tableau ci-après:

SITUATION	DESCRIPTION	CLASSE
Situation critique (pluies abondantes), nécessitant un suivi rigoureux du taux du coagulant.	Température faible, turbidité de l'eau brute élevée, taux du coagulant légèrement élevé (période hivernale)	C1
Opération anormale	La valeur du taux du coagulant importante; température légèrement élevée, ne correspondant pas à une période d'hiver, turbidité de l'eau brute ordinaire.	C2
Opération normale nécessitant un suivi rigoureux	Température élevée, pH légèrement élevé, le taux du coagulant élevé, risque de formation d'algues (période d'été)	C3
Opération normale	Les valeurs des variables correspondant aux conditions normales, stables et typiques à la fin de la saison d'hiver (température modérée)	C4

Tableau 3.2. Description des modes de fonctionnement de la station

Les résultats de classification correspondant au fonctionnement de la station le long de l'année 2010, reflètent fidèlement la réalité du terrain. On trouve ainsi, la station fonctionne en situations C1 et C4 durant la période allant du mois d'octobre au mois de mai, et en situation C3 durant la période allant de mai à octobre, avec un passage par la situation anormale C2, qui signifie la présence de défauts nécessitant l'intervention du gestionnaire.

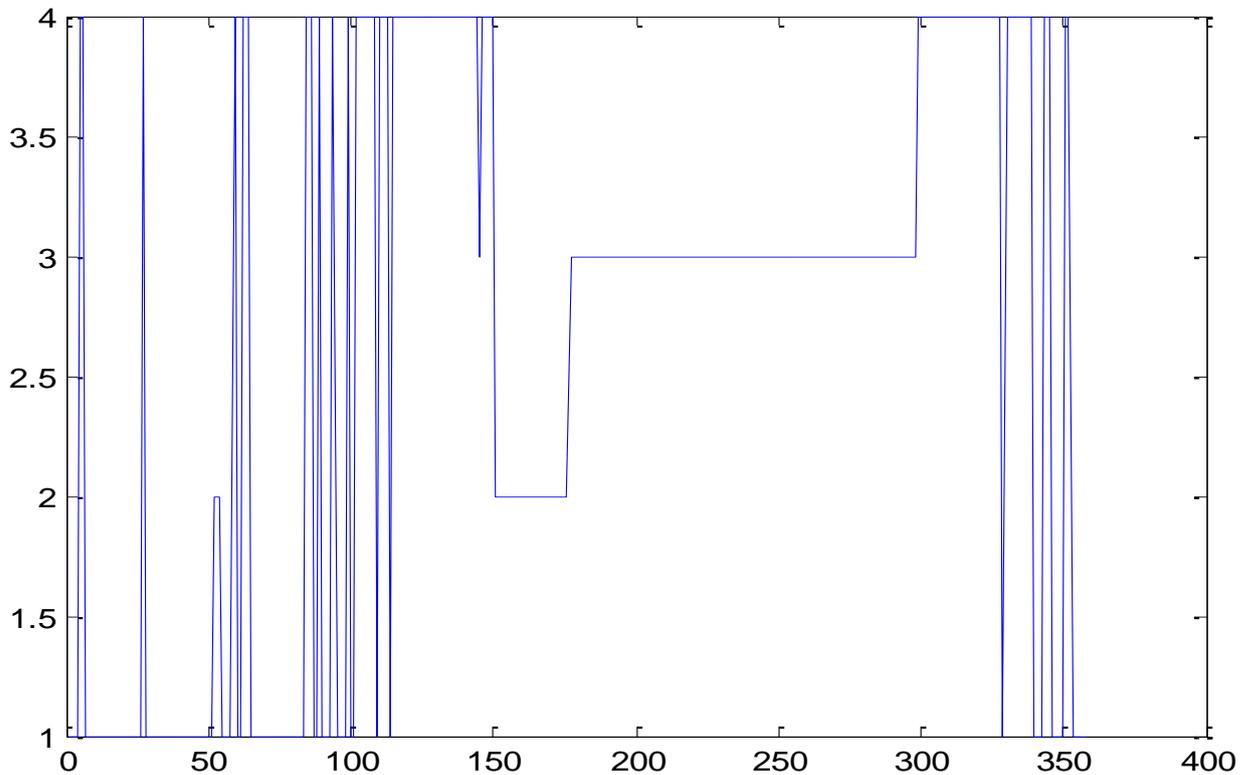


Figure 3.14. Modes de fonctionnement de la station (année 2010)

Les modes de fonctionnement de la station étant déterminés, nous aborderons dans la phase qui suit le diagnostic en ligne de la station (phase 2).

3.3.2. Phase de reconnaissance en ligne

Avant d'appliquer la méthode de diagnostic aux données réelles de la station de TAKSEBT, nous avons testé notre programme de calcul, à travers deux exemples pratiques, pour faire une classification d'une observation donnée via la règle de décision adoptée. Nous avons pris, pour cela, des paramètres s_k se rapportant aux seuils des degrés d'appartenance similaires pour l'ensemble des quatre classes ($s_k \approx 0,2$), $T_a=0,9$.

Exemple 01: Cas d'une donnée atypique

Le premier test du programme correspond à une observation (vecteur t1) atypique ne ressemblant guère aux profils des différentes classes. Les résultats du programme, illustrés graphiquement à travers la figure 3.15, montrent clairement qu'il s'agit d'un cas de rejet de distance. Les degrés d'appartenance y afférents sont repris dans le tableau 3.3.

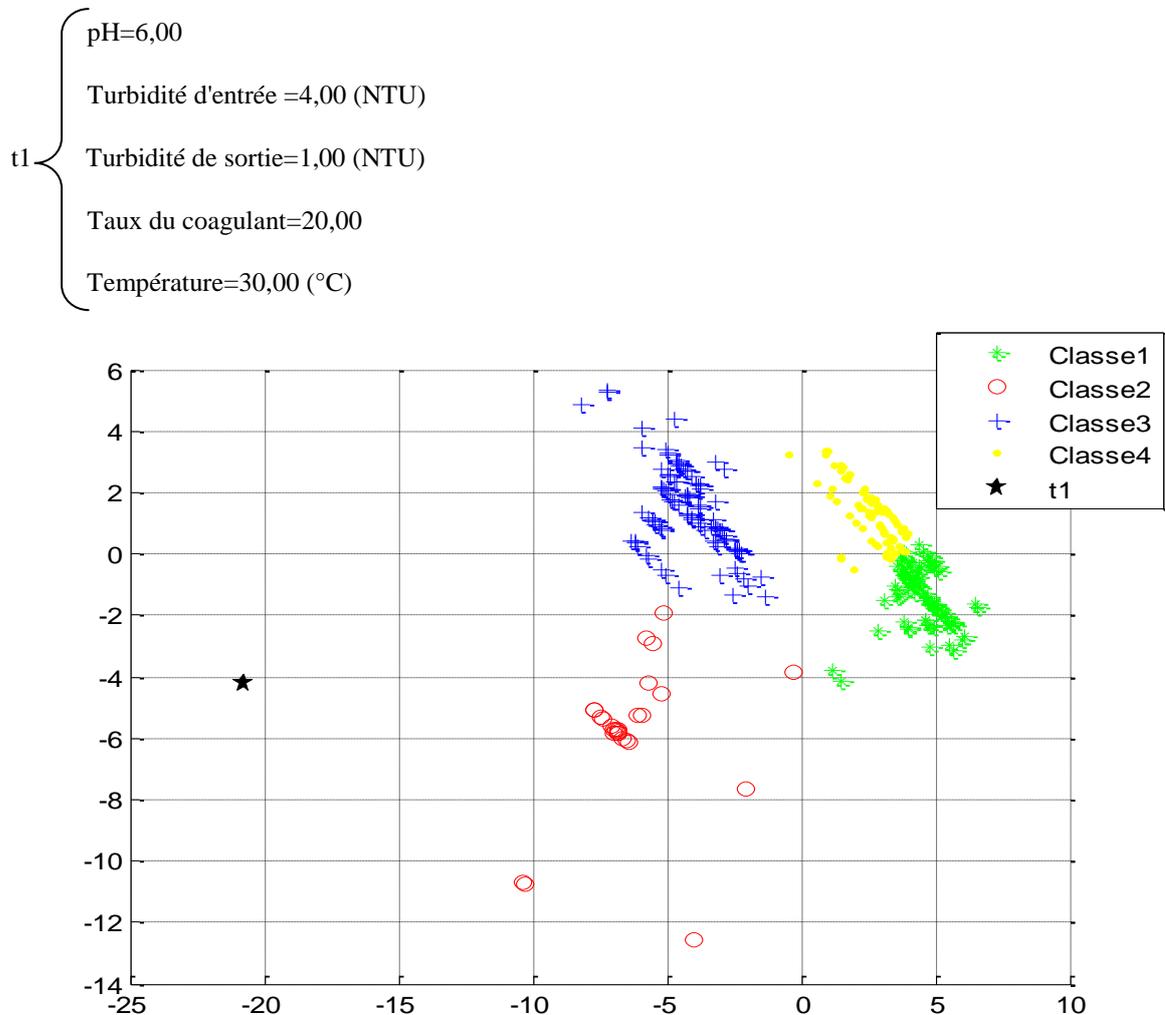


Figure 3.15. Classification d'une nouvelle observation t1 (cas de rejet en distance)

Classe	Degré d'appartenance
1	$0.0208 \cdot 10^{-3}$
2	$0.8220 \cdot 10^{-3}$
3	$0.1272 \cdot 10^{-3}$
4	$0.0387 \cdot 10^{-3}$

Tableau 3.3. Degrés d'appartenance du vecteur t1

Exemple 2:

Nous prenons dans ce deuxième exemple un vecteur t2 dont les paramètres ressemblent aux observations liées au fonctionnement du système durant l'année 2010. Les résultats du programme sont représentés à travers la figure 3.17 et le tableau 3.4.

t2 {
 pH=7,71
 Turbidité d'entrée =2,33 (NTU)
 Turbidité de sortie=0,30 5 (NTU)
 Taux du coagulant=11,00
 Température=18,00 (°C)

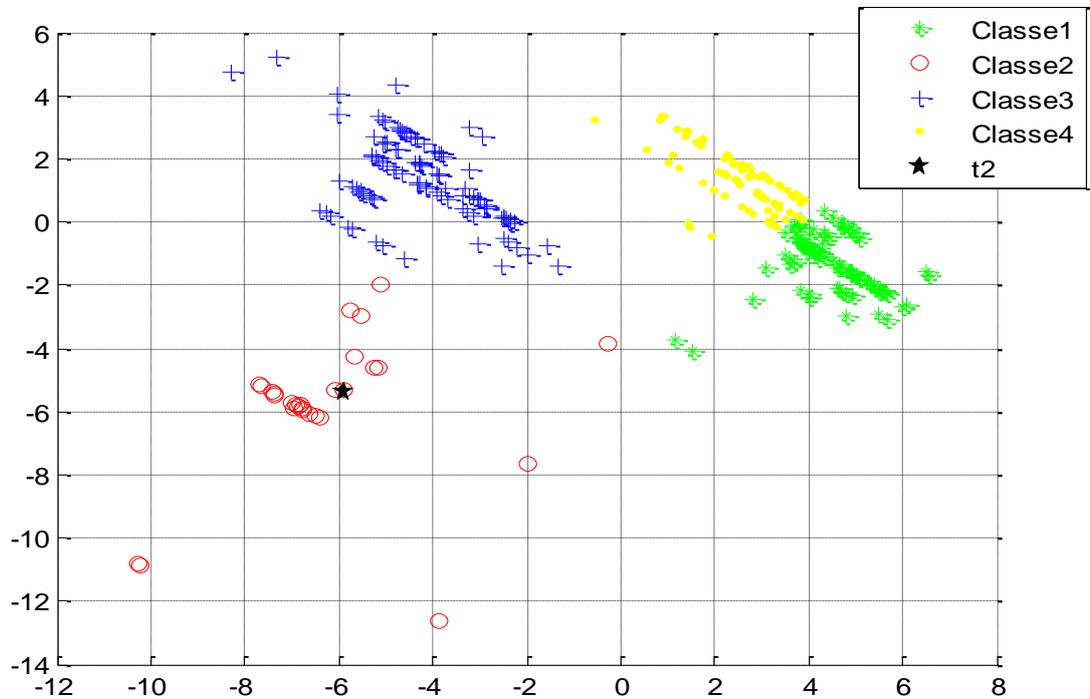


Figure 3.16. Classification d'une nouvelle observation t2

Classe	Degré d'appartenance
1	0.0006
2	0.8585
3	0.0042
4	0.0010

Tableau 3.4. Degrés d'appartenance du vecteur t2

Les résultats de l'application montrent clairement qu'il s'agit d'un point appartenant à la classe 2 affichant un mode de fonctionnement anormal, caractérisé par une concentration de coagulant très élevée. L'intervention du gestionnaire de la station dans une telle situation est nécessaire pour déterminer la cause d'utilisation du coagulant à un dosage élevé qui ne concorde pas avec la valeur de la turbidité.

Après avoir illustré ces deux exemples, nous verrons dans ce qui suit, les résultats du programme concernant la reconnaissance en ligne du fonctionnement de la station objet de notre application, sur une période de trois mois (période hivernale) de l'année 2011. L'évolution des cinq descripteurs de la station durant cette période est représentée dans la figure 3.17.

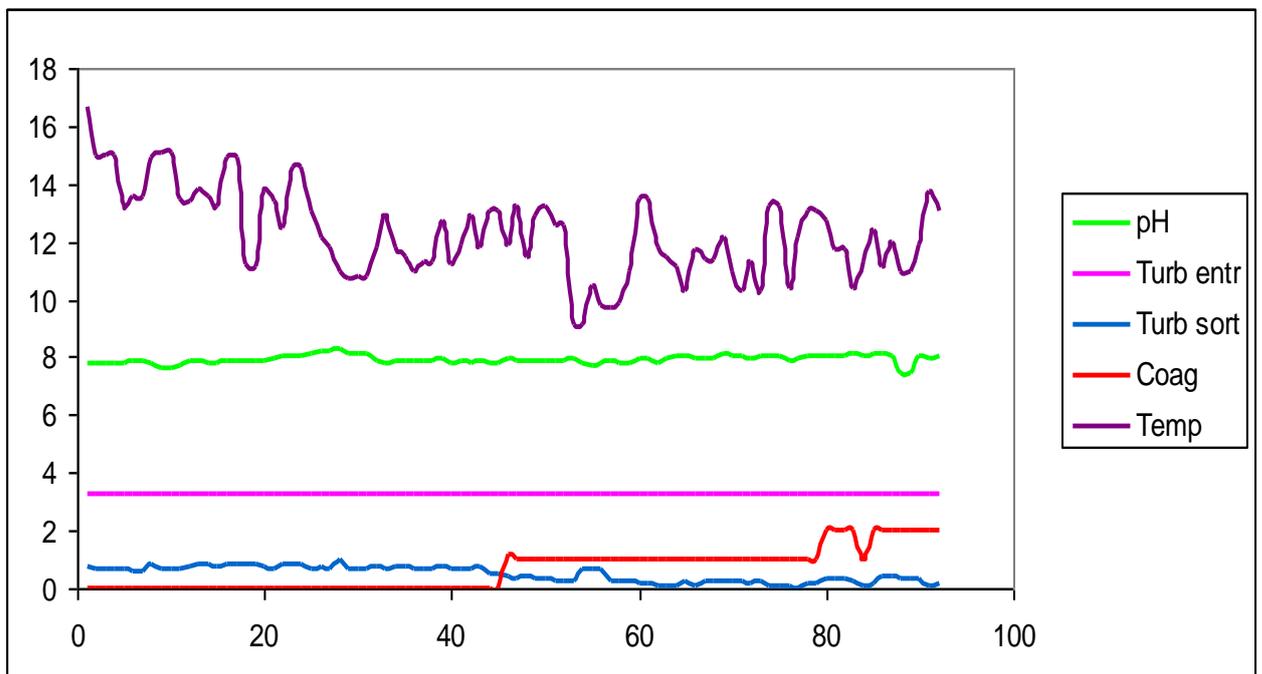


Figure 3.17. Evolution des cinq paramètres de la station durant la période hivernale

Le suivi des différentes situations attendues dans la station, durant la période en question, peut-être réalisé en associant toute nouvelle observation à une des classes déterminées au préalable, tout en faisant ressortir les cas de rejet (rejet en distance ou d'ambiguïté).

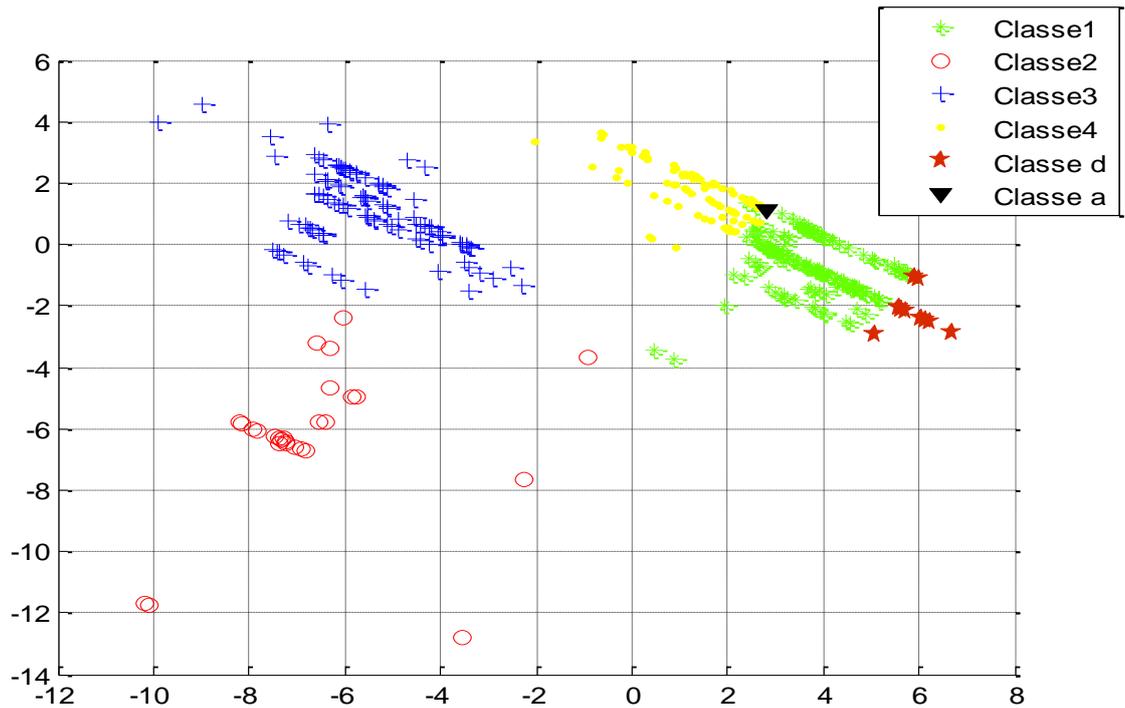


Figure 3.18. Reconnaissance en ligne des données (période hivernale 2011)

Nous pouvons observer à partir des résultats de classification des observations en question, l'apparition de deux nouvelles classes renfermant 16 points, présentant des cas de rejet d'ambiguïté (classe a) et de distance (classe d). Les données s'y rapportant sont repris avec les valeurs des degrés de confiance y afférents, dans les tableaux ci-après:

Données rejetées en ambiguïté				
pH	Turb ent	Turb sort	Coag	Temp
8,03	3,26	0,81	0,000	14,60
8,03	3,26	0,81	0,000	14,60

Tableau 3.5. Classe des données objet du rejet en ambiguïté (classe a)



Degrés d'appartenance			
C1	C2	C3	C4
0.2045	0.0016	0.0022	0.2368
0.2045	0.0016	0.0022	0.2368

Tableau 3.6. Degrés d'appartenance associés à la classe a

Données rejetées en distance				
pH	Turb ent	Turb sort	Coag	Temp
8,13	3,26	0,69	0	10,7
8,1	3,26	0,68	0	10,8
8,1	3,26	0,68	0	10,8
7,97	3,26	0,24	1	9,1
7,81	3,26	0,63	1	9,1
7,73	3,26	0,65	1	10,5
7,77	3,26	0,64	1	9,8
7,85	3,26	0,27	1	9,7
7,8	3,26	0,23	1	9,9
8,04	3,26	0,23	1	10,3
8,05	3,26	0,22	1	10,3
8,06	3,26	0,24	1	10,3
7,9	3,26	0,1	1	10,4
8,13	3,26	0,24	2	10,4

Tableau 3.7. Classe des données objet du rejet en distance (classe d)



Degrés d'appartenance			
C1	C2	C3	C4
0,0838	0,001	0,0006	0,0114
0,0924	0,001	0,0006	0,0121
0,0924	0,001	0,0006	0,0121
0,0232	0,0009	0,0004	0,0046
0,0232	0,0009	0,0004	0,0046
0,0841	0,0012	0,0006	0,0101
0,0427	0,001	0,0005	0,0067
0,039	0,001	0,0005	0,0063
0,0468	0,0011	0,0005	0,0071
0,0688	0,0011	0,0006	0,0089
0,0687	0,0011	0,0006	0,0089
0,0687	0,0011	0,0006	0,0089
0,0752	0,0012	0,0006	0,0094
0,0633	0,0015	0,0007	0,0085

Tableau 3.8. Degrés d'appartenance associés à la classe d

Le rôle de l'expert est primordial pour l'interprétation de ces données et la prise de décision quant à l'affectation des points ambigus et l'ajout d'éventuelles classes objet du

rejet de distance. Les deux points de la classe ont des degrés d'appartenance aux classes 1 et 4 très proche l'un de l'autre, avec une tendance vers le quatrième mode de fonctionnement. Toutefois nous remarquons un retour vers le premier mode de fonctionnement (classe 1) pour les observations qui viennent juste après.

Concernant la classe d représentant les rejets de distances (au nombre de 14) dont les degrés d'appartenance sont repris dans le tableau 3.8, nous remarquons qu'il s'agit de situations caractérisées par une tendance baissière de la concentration du coagulant et de la température de l'eau traitée, se situant en deçà des valeurs constatées pour la classe 1, mais ne donnant pas forcément lieu à l'adoption d'un nouveau mode de fonction pour la station.

Hormis les deux situations de rejet (ambiguïté, distance), le mode de fonctionnement prédominant est celui correspondant à la première classe caractérisée par une augmentation de la turbidité de l'eau brute, nécessitant un suivi rigoureux du dosage du coagulant. Un passage par le mode normal correspondant à la classe 4 a été ainsi relevé durant le début de la saison hivernale (voir figure 3.19).

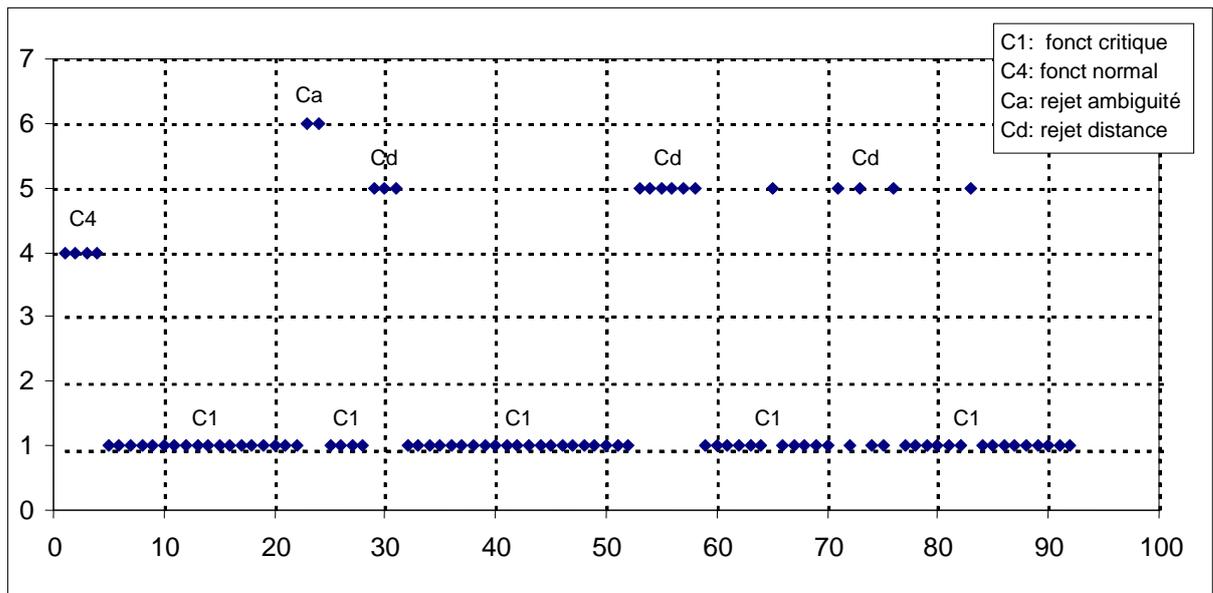


Figure 3.19. Reconnaissance en ligne du fonctionnement de la station durant: 90 jours de la période hivernale 2011

3.4. Conclusion

À travers ce troisième chapitre, nous avons essayé de mettre en évidence l'utilité de la méthode de reconnaissance des formes floue pour le diagnostic du fonctionnement d'un système industriel et la détection de situations présentant des défauts éventuels. Le programme de calcul que nous avons développé en MATLAB7 a été appliqué avec succès

pour le diagnostic du fonctionnement de la station de production d'eau potable de TAKSEBT. L'algorithme MPCM a été utilisé pour faire un apprentissage hors ligne sur le fonctionnement de la station en faisant exploiter une base de données multidimensionnelle se rapportant aux caractéristiques de l'eau traitée le long de la chaîne de production durant l'année 2010. Cette démarche nous a permis de déterminer les différents modes de fonctionnement de la station qui sont au nombre de quatre. Par la suite le programme de calcul a été utilisé, dans une deuxième phase, pour effectuer un diagnostic en ligne et déterminer la situation réelle de la station.

La reconnaissance en ligne via la méthode adoptée nous a permis, à travers les exemples pratiques traités, de connaître en temps réel les situations de fonctionnement, y compris celles présentant une défaillance dans la station et indiquées par le mode de fonctionnement 2 (anormal). De telles situations nécessitent l'intervention du gestionnaire pour la vérification du fonctionnement du coagulateur en fonction des autres paramètres caractérisant la qualité de l'eau (pH, turbidité, température).

Conclusion générale

Nous avons présenté, dans notre travail, une méthodologie de diagnostic des défaillances dans les systèmes industriels, basée sur la reconnaissance des formes floues (**RdF floue**). Cette méthodologie suppose deux étapes principales:

- Une étape de classification des données historiques et de modélisation des modes de fonctionnement du système (apprentissage hors ligne);
- Une étape de reconnaissance en ligne (en temps réel) du mode de fonctionnement du système (apprentissage en ligne).

Dans la première étape, le vecteur formes est déterminé en fonction des observations caractérisant le système étudié, et ce, en utilisant les méthodes de sélection ou d'extraction de paramètres. Les méthodes de classification interviennent par la suite pour déterminer le mode de fonctionnement du système. L'algorithme **MPCM** (Modified Possibilist C-Means) a été retenu, dans cette phase, pour la classification des données dans un contexte d'apprentissage non supervisé, au regard des avantages qu'il présente par rapport aux autres algorithmes (FCM, PCM).

La deuxième étape de la méthodologie consiste à définir à quelle classe affecter une nouvelle observation recueillie sur le système à un instant donné, ce qui conduit à définir le mode de fonctionnement du système à cet instant (reconnaissance en ligne). Pour ce faire, nous avons choisi la règle de décision du rapport d'appartenance présentant plus de souplesse par rapport aux autres règles de décision.

Le diagnostic en ligne du système étudié nous donne la possibilité de connaître les situations correspondant aux modes de fonctionnement critique ou anormal, avec une quantification des descripteurs du système en question permettant de connaître conséquemment la cause de la défaillance relevée.

En se référant à l'algorithme général de la méthode adoptée (**RdF floue**), résumé dans le chapitre 2, nous avons développé un programme de calcul en **MATLAB7**.

Nous avons ainsi essayé de mettre en évidence l'utilité de la méthode de reconnaissance des formes floue pour le diagnostic du fonctionnement d'un système industriel et la détection de situations présentant des défauts éventuels. Le programme développé a été appliqué avec succès pour le diagnostic du fonctionnement de la station de production d'eau potable de TAKSEBT. Un apprentissage hors ligne sur le fonctionnement de la station a été réalisé en faisant exploiter une base de données multidimensionnelle reprenant les valeurs des descripteurs de la chaîne de production durant l'année 2010. Cette démarche nous a permis de déterminer les différents modes de fonctionnement de la station qui sont au nombre de quatre.

Par la suite, le programme de calcul a été utilisé pour faire un diagnostic en ligne et déterminer la situation réelle de la station, y compris celle présentant une défaillance dans la station et indiquée par le mode de fonctionnement 2 (anormal). Une telle situation nécessite l'intervention du gestionnaire pour la vérification du fonctionnement du coagulateur en fonction des autres paramètres caractérisant la qualité de l'eau (pH, turbidité, température).

De manière générale, plusieurs perspectives peuvent être envisagées pour notre travail, notamment en ce qui concerne le domaine d'application de la méthode. Nous suggérons, à cet effet, d'adopter une approche pluridisciplinaire, nécessitant l'intervention d'un groupe de recherche, pour le diagnostic de systèmes industriels plus pointus, en mettant l'accent sur l'aspect préventif du diagnostic, par l'anticipation, d'une manière automatique, de l'évolution d'un mode de fonctionnement normal vers un mode anormal. Une approche pareille permettra sans doute de minimiser les coûts de maintenance des chaînes de productions.

Références bibliographiques

- [ADR 00] O.ADROT, « Diagnostic à base de modèles incertains utilisant l'analyse par intervalles : L'approche bornante » thèse de doctorat de l'institut national polytechnique de Lorraine, 2000.
- [ALA 04] R-M.ALAOU, « Conception d'un module de diagnostic à base des suites de bandes temporelles en vue de la supervision des procédés énergétiques, Application en ligne à un générateur de vapeur » thèse de doctorat de l'université des sciences et technologies de Lille, 2004.
- [ALB 03] S. ALBAYRAK., F.AMASYALI, « Fuzzy C- means clustering on medical diagnostic systems» International XII. Turkish symposium on artificial intelligence and neural networks, TAINN, 2003.
- [ALH 05] M.ALHAJ DIBO « Validation de données et diagnostic des systèmes incertains à l'aide de l'analyse par intervalle » thèse de doctorat de l'institut national polytechnique de Lorraine, 2005.
- [AMM 07] O.AMMOR., N. RAISS., K.SLAOUI, « Détermination du nombre optimal de classe présentant un fort chevauchement» Revue MODULAD, pp31-42, 2007.
- [ARR 02] D.ARRIVault, « Apport des graphes dans la reconnaissance non-contrainte de caractères manuscrits anciens » thèse de doctorat de l'université de Poitiers, 2002.
- [ATI 10] J.C.ATINE, « A fuzzy clustering approach for supervision of biological processes by image processing» international archives of photogrammetry, remote sensing and spatial information sciences, Vol XXXVIII, part 5commission V symposium, pp 45-50, UK, 2010.
- [BAC 02] S.BACHIR, « Contribution au diagnostic de la machine asynchrone par estimation paramétrique» thèse de doctorat de l'université de Poitiers, 2002.
- [BEN 05] R.BENSAADI, H.MOUSS, « Diagnostic de défaillances par reconnaissance de formes » 3rd International Conference: SETIT, Tunisie, 2005.
- [BEN 07] R.BENSAADI, H.MOUSS, & D.MOUSS, « une méthode à base de la reconnaissance de formes floue pour le diagnostic des procédés industriels » CPI' 2007, Rabat, Maroc.

- [BOU 95] B. BOUCHON-M, « La logique floue et ses applications » Addison Wesley, Paris, 1995.
- [BOU 01] T.BOUMEGOURA, « Recherche de signature électromagnétique des défauts dans une machine asynchrone et synthèse d'observateurs en vue du diagnostic » thèse de doctorat de l'école centrale de Lyon, 2001.
- [BRU 90] J.BRUNET, M.LABARRÈRE, D.JAUME, A.RAULT, M.VERGÉ, « Détection et diagnostic de pannes : Approche par modélisation » Hermès, Paris, 1990.
- [BUI 07] V-P.BUI, « Diagnostic des machines électriques par l'analyse du champ magnétique de fuite: application à l'identification des défauts rotoriques d'un alternateur à vide » thèse de doctorat de l'institut national polytechnique de Grenoble, 2007.
- [CAS 03] R.CASIMIR, « Diagnostic des défauts des machines asynchrones Par reconnaissance des formes » thèse de doctorat de l'université de Lyon, 2003.
- [CHE 97] V. CHEN, C. ROCHER, M. ROUSSEL, « Classification automatique des roulements coniques par reconnaissance des formes floue » seizième colloque GRETSI, pp 311-314, Grenoble, 1997.
- [COC 04] V.COCQUEMPOT «Contribution à la surveillance des systèmes industriels complexes» habilitation à diriger des recherches, université des sciences et technologies de Lille, 2004.
- [DEB 07] A.DEBIOLLES, « Diagnostic de systèmes complexes à base de modèle interne, reconnaissance des formes et fusion d'information : Application au diagnostic des circuits de voie ferroviaires » thèse de doctorat de l'université de technologie Compiègne, Compiègne, 2007.
- [DEG 08] DEGRÉMONT, « Notice d'exploitation: Destinée au personnel de maîtrise», STE TAKSEBT, Algérie, EA04008, 18/09/2008.
- [DEN 01] T.DENŒUX, « Diagnostic par reconnaissance des formes : Approche non probabilistes » *Diagnostic, intelligence artificielle et reconnaissance des formes*, chap.3, Hermès, Paris, 2001.
- [DER 09] H.DERBEL, « Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de systèmes dynamiques hybrides» thèse de doctorat de l'université de Grenoble I et l'université de Tunisie, 2009.
- [DUB 90] B.DUBUISSON, « Diagnostic et reconnaissance des formes » Hermès, Paris, 1990.
- [DUB 01] B.DUBUISSON, « Diagnostic, intelligence artificielle et reconnaissance des formes » Hermès, Paris, 2001.
- [GRI 07] V.H.GRISALES-P, « Modélisation et commande floues de type TAKAG-SUGENO. Appliquées ç un bioprocédés de traitement des eaux usées» thèse de doctorat de l'université de Toulouse III et l'université de Colombie, 2007.

- [HER 06] H-R.HERNANDEZ-D-L, «Supervision et diagnostic des procédés de production d'eau potable» thèse de doctorat de l'institut des sciences appliquées de Toulouse, 2006.
- [KEM 04] T.KEMPOWSKY, « Surveillance de procédés à base des méthodes de classification: Conception d'un outil d'aide pour la détection et le diagnostic de défaillances», thèse de doctorat de l'institut des sciences appliquées de Toulouse, 2004.
- [KHA 09] A.KHATIR, « Etude comparative des modèles des machines asynchrones utilisés en diagnostic des défauts » thèse de magister en électrotechnique de l'université de Sétif, Algérie, 2009.
- [KHO 07] L.KHODJA, « Contribution à la classification floue non supervisée » thèse de doctorat de l'université de Savoie.
- [LER 98] P.LERAY, « Apprentissage et diagnostic de systèmes complexes: réseaux de neurones et réseaux bayésiens. Application à la gestion en temps réel du trafic téléphonique français » thèse de doctorat de l'université Paris 6, 1998.
- [MAS 01] M.MASSON, Y.GRANDVALET, « Réseaux de neurones pour le diagnostic » *Diagnostic, intelligence artificielle et reconnaissance des formes*, chap.4, Hermès, Paris, 2001
- [MOK 07] A.MOKHTARI, «Diagnostic des systèmes hybrides : développement d'une méthode associant la détection par classification et la simulation dynamique» thèse de doctorat de l'université de Toulouse, 2007.
- [MOU 02] M-S.MOUCHAWEH, « Conception d'un système de diagnostic adaptatif et prédictif basé sur la méthode Fuzzy Pattern Matching pour la surveillance en ligne des systèmes évolutifs: Application à la supervision et au diagnostic d'une ligne de peinture au trempé » thèse de doctorat de l'université de Reims Champagne-Ardenne, 2002.
- [NAI 00] M.S.NAIT-SAID, M. E.BENBOUZID, A.BENCHAIIB, « Detection of broken bars in induction motors using an extended Kalman filter for rotor resistance sensorless estimation » IEEE transactions on energy conversion, vol. 15, no. 1, march 2000.
- [NOU 05] H.NOURA, « Diagnostic Et Tolérance aux Fautes » Ecole de formation Mécatronique : Recherche et Applications, 2005.
- [OND 06] O.ONDEL, «Diagnostic par reconnaissance des formes : application a un ensemble convertisseur – machine asynchrone » thèse de doctorat de l'université de Lyon, 2006.
- [OUK 04] L.OUKHELLOU, P.AKNIN, M.NADJI, « Utilisation de la régression PLS et d'un algorithme de coalescence floue pour le suivi de point de fonctionnement : Application au diagnostic de la transmission voie/ machine du TGV » Communication n°C2I 2004-65, pp 1-8, 2004.
- [PAL 05] N.R.PAL., K.PAL., J.M. KELLER., J.C.BEZDEK, « Possibilistic fuzzy c-means clustering algorithm» IEEE Transactions on fuzzy systems, Vol 13.n°4,

- pp 517-530, 2005.
- [RAG 03] N.RAGOT, « MÉLIDIS : Reconnaissance de formes modélisation mixte intrinsèque/discriminante à de systèmes d'inférence floue hiérarchisés » thèse de doctorat de l'université de Rennes 1, 2003.
- [ROC 06] E.ROCHA-LOURES, « Surveillance et diagnostic des phases transitoires des systèmes hybrides bases sur l'abstraction des dynamiques continues par réseau de Petri temporel flou» thèse de doctorat de l'université de Toulouse, 2006.
- [SAI 01] C. SAINT-JEAN, «Classification paramétrique robuste partiellement supervisée en reconnaissance des formes» thèse de doctorat de l'université de La Rochelle, 2001.
- [SEM 07] M.SEMCHEDINE., L.TOUMI., A.MOUSSAOUI, «Classification adaptative robuste pour la segmentation d'images IRM cérébrales» 3^{ème} journées internationales sur l'informatique graphique, pp 151-158, 2007.
- [SOW 09] B.SOWMYA, « Colour image segmentation using soft computing techniques» International journal of soft computing applications, pp 69-80, 2009.
- [THA 08] Y.THARRAULT, « Diagnostic de fonctionnement par analyse en composantes principales : Application à une station de traitement des eaux usées» thèse de doctorat de l'Institut National Polytechnique de Lorraine, 2008.
- [THO 99] J.H.THOMAS,« Diagnostic d'un système non stationnaire à partir d'une approche de reconnaissance des formes floue. Application au diagnostic de cliquetis moteur» Traitement du signal, volume 16-n°3, pp 204-216, 1999.
- [TRA 10] M.A.TRAORE, « supervision adaptative et pronostic de défaillances pour la maintenance prévisionnelle de systèmes évolutifs complexes» thèse de doctorat de l'université Lille 1, 2010.