

الجمهورية الجزائرية الديمقراطية الشعبية  
وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR- ANNABA UNIVERSITY  
UNIVERSITE BADJI MOKHTAR - ANNABA



جامعة باجي مختار - عنابة

Faculté: Sciences de l'ingéniorat

Année : 2018

Département: Electronique

## THÈSE

Présentée en vue de l'obtention du diplôme de Doctorat en sciences

**Diagnostic de l'état de fonctionnement d'un procédé  
biologique d'épuration des eaux usées**

### Intitulé

Option : Automatique

Par : **BOUZENAD Khaled**

DIRECTEUR DE THÈSE : RAMDANI Messaoud Pr. Université d'ANNABA.

### DEVANT LE JURY

**PRESIDENT :** DOGHMANE Nouredine  
**EXAMINATEURS :** HARKAT Mohamed Faouzi

Pr. Université d'ANNABA.  
Pr. Université d'ANNABA.

LACHOURI Abderrazak

Pr. Université de SKIKDA.

BOUDEN Toufik

Pr. Université de JIJEL.

KOURD Yahia

M.C.A Université de SOUKAHRAS.

## ملخص

تكتسب عمليات رصد الأعطال في أقرب وقت ممكن ثم إيجاد وإزالة العوامل المسببة لها أهمية كبيرة للتشغيل الآمن والإنتاجية الحسنة. وكثيراً ما يفترض الرصد التقليدي للعمليات باستخدام تحليل المركبات الرئيسية (*Analyse en Composantes Principales PCA*) أن بيانات العملية تتبع توزيع عادي. ومع ذلك، لا يمكن استيفاء هذا النوع من القيود من الناحية العملية لأن العديد من العمليات الصناعية كثيراً ما تغطي حالات تشغيل ذات توزيعات متعددة. للتغلب على هذه الصعوبة، يمكن دمج النموذج *PCA* مع مخططات التحكم اللامعلمية التي لا تتطلب افتراضية للتوزيع. ومع ذلك، لا يزال هذا النهج يستخدم حد ثقة ثابت حيث يتم إنشاء معدل عالي نسبياً من الإنذارات الخاطئة. على الرغم من أن *PCA* غير الخطية التي تستخدم شبكات عصبية عنقودية تلعب دوراً مهماً في مراقبة العمليات الصناعية، إلا أنه من الصعب تصميم إحصاءات مراقبة صحيحة وحدود ثقة تحقق أداءً جيداً. في هذا العمل، تم اقتراح إستراتيجية مراقبة جديدة باستخدام شبكة عصبية عنقودية معززة (*Enhanced Bottleneck Neural Network EBNN*) مع حد ثقة تكيفي للبيانات غير العادية. الفكرة الأساسية وراء ذلك هو استخراج شرائح متجانسة داخلياً من مجموعات البيانات الطبيعية التاريخية عن طريق ملء نموذج خليط من التوزيعات العادية (*Gaussian Mixture Model GMM*) واستناداً إلى افتراض أن بيانات العملية تتبع توزيع عادي ضمن نمط تشغيل، يمكن تحديد حد ثقة محلي. يتم استخدام *EBNN* لإعادة بناء بيانات المدخلات وتقدير احتمالات الانتماء إلى أنظمة التشغيل المحلية المختلفة، وفقاً للنموذج الذي تم وضعه. يتم الكشف عن أي حدث غير طبيعي في قياسات الإدخال إذا كان خطأ التنبؤ المربع (*Squared Prediction Error SPE*) كبيراً جداً، أو أعلى من عتبة ثقة معينة التي بدورها تم جعلها متكيفة. علاوة على ذلك، في هذا العمل تم توظيف مؤشر صحة المستشعر (*Sensor validity Index SVI*) بنجاح لتحديد العطب المكتشف. توضح النتائج أنه، بالمقارنة مع *PCA* الغير خطية التقليدية، يمكن للنهج المقترح أن يقلل بشكل فعال من عدد الإنذارات الزائفة، ومن المتوقع بالتالي أن يساعد في مراقبة العديد من العمليات المعقدة بشكل أفضل.

**الكلمات المفتاحية:** التشخيص؛ التحكم في العمليات الإحصائية المتعددة المتغيرات (*MSPC*)؛ الشبكة العصبية عنق الزجاجة (*BNN*)؛ نموذج خليط غاوسي (*GMM*)؛ حد الثقة التكيفي (*ACL*)؛ محطة معالجة مياه الصرف الصحي (*WWTP*)؛ نموذج المحاكاة القياسي رقم: 1 (*BSM1*).

## RÉSUMÉ

*Le diagnostic de défauts et de dysfonctionnements des processus le plus tôt possible, puis l'identification et l'élimination des facteurs en cause possèdent une véritable importance pour un fonctionnement sûr et une productivité meilleure. Le diagnostic conventionnel des processus utilisant l'analyse en composantes principales (ACP) suppose souvent que les données du processus suivent une distribution gaussienne. Cependant, ce type de contrainte ne peut pas être satisfait dans la pratique car de nombreux processus industriels couvrent souvent plusieurs modes de fonctionnement. Pour surmonter cette difficulté, l'ACP peut être combinée avec des cartes de contrôle non paramétriques pour lesquelles il n'y a aucun besoin de supposition sur la distribution. Cependant, cette approche utilise toujours une limite de confiance constante où un taux relativement élevé de fausses alarmes est généré. Bien que la ACP non linéaire (ACP<sub>NL</sub>) utilisant des réseaux de neurones auto-associatifs à couche d'étranglement joue un rôle important dans la surveillance des processus industriels, il est difficile de concevoir des statistiques de surveillance et des limites de confiance correctes qui vérifient les nouvelles performances. Dans ce travail, une nouvelle stratégie de surveillance utilisant un réseau neuronal à couche d'étranglement amélioré (Enhanced Bottleneck Neural Network EBNN) avec une limite de confiance adaptative pour les données non gaussiennes est proposée. L'idée de base est d'extraire des segments homogènes internes à partir des ensembles de données historiques normaux en remplissant un modèle de mélange gaussien (usuellement abrégé par l'acronyme anglais GMM pour Gaussian Mixture Model). En partant de l'hypothèse que les données de processus suivent une distribution gaussienne dans un mode de fonctionnement, une limite de confiance locale peut être établie. L'EBNN est utilisé pour reconstruire les données d'entrée et estimer les probabilités d'appartenance aux différents régimes de fonctionnement locaux, comme étaient modélisés par MMG. Un événement anormal pour un vecteur de mesure d'entrée est détecté si l'erreur quadratique de prédiction (Squared Prediction Error) est assez grande, ou au-dessus d'un certain seuil qui est rendu adaptatif. De plus, l'indice de validité du capteur (Sensor Validité Indexes) est utilisé avec succès pour identifier la variable défectueuse détectée. Les résultats démontrent que, par rapport à l'ACP<sub>NL</sub>, l'approche proposée peut effectivement réduire le nombre de fausses alarmes, et devrait donc mieux surveiller de nombreux processus pratiques.*

**Mots Clés :** *Diagnostic; Contrôle de processus statistique multivarié (MSPC); Réseau de neurones à couche d'étranglement(BNN), modèle de mélange gaussien (GMM); Limite de confiance adaptative (ACL); Station de traitement des eaux usées (WWTP);Modèle de simulation de référence n° 1 (BSM1)*

## **ABSTRACT**

*Monitoring process upsets and malfunctions as early as possible and then finding and removing the factors causing the respective events is of great importance for safe operation and improved productivity. Conventional process monitoring using principal component analysis (PCA) often supposes that process data follow a Gaussian distribution. However, this kind of constraint cannot be satisfied in practice because many industrial processes frequently span multiple operating states. To overcome this difficulty, PCA can be combined with nonparametric control charts for which there is no assumption need on the distribution. However, this approach still uses a constant confidence limit where a relatively high rate of false alarms are generated. Although nonlinear PCA (NLPCA) using autoassociative bottleneck neural networks plays an important role in the monitoring of industrial processes, it is difficult to design correct monitoring statistics and confidence limits that check new performance. In this work, a new monitoring strategy using an enhanced bottleneck neural network (EBNN) with an adaptive confidence limit for non Gaussian data is proposed. The basic idea behind it is to extract internally homogeneous segments from the historical normal data sets by fitting a Gaussian mixture model (GMM). Based on the assumption that process data follow a Gaussian distribution within an operating mode, a local confidence limit can be established. The EBNN is used to reconstruct input data and estimate probabilities of belonging to the various local operating regimes, as modelled by GMM. An abnormal event for an input measurement vector is detected if the squared prediction error (SPE) is too large, or above a certain threshold which is made adaptive. Moreover, the sensor validity index (SVI) is employed successfully to identify the detected faulty variable. The results demonstrate that, compared with NLPCA, the proposed approach can effectively reduce the number of false alarms, and is hence expected to better monitor many practical processes.*

**Keywords:** *Diagnostic, Multivariate statistical process control (MSPC); Bottleneck neural network (BNN); Gaussian mixture model (GMM); Adaptive confidence limit (ACL); Wastewater treatment plant (WWTP); Benchmark simulation model No. 1 (BSM1)*



Je dédie ce travail à mes parents,  
mes frères,  
mes soeurs,  
ma femme,  
ma fille,  
et toute ma famille.

## REMERCIEMENTS

Je remercie Dieu de m'avoir donné la force et la patience nécessaire pour mener à bonne fin mon projet de Doctorat.

Je remercie vivement mon encadreur monsieur RAMDANI Messaoud Pr. à l'université d'ANNABA pour ses conseils constructifs. Je souhaite ensuite remercier messieurs : DOGHMANE Noureddine Pr. à l'université d'ANNABA, HARKAT Mohamed Faouzi Pr. à l'université d'ANNABA, LACHOURI Abderrazak Pr. à l'université de SKIKDA, BOUDEN Toufik Pr. à l'université de JIJEL et KOURD Yahia M.C.A à l'université de SOUK AHRAS d'avoir accepté d'examiner ce manuscrit et de faire partie du jury de cette thèse.

Mes remerciements s'adressent également à ceux qu'ont aidé à réaliser ce travail dont je n'ai pas cité leurs noms.

## TABLE DES MATIÈRES

<b>INTRODUCTION GÉNÉRALE . . . . .</b>	<b>1</b>
<b>CHAPITRE 1: DESCRIPTION DES PROCÉDÉS DU TRAITEMENT DES EAUX USÉES . . . . .</b>	<b>5</b>
1.1 Introduction . . . . .	5
1.1.1 Principes généraux de traitement des eaux usées . . . . .	8
1.1.2 Pré-traitement . . . . .	9
1.1.3 Traitement par voie biologique . . . . .	9
1.1.4 Traitement du carbone et de l'azote . . . . .	10
1.2 Benchmark Simulation Model 1 (BSM1) . . . . .	11
1.2.1 Variables d'état . . . . .	13
1.2.2 La liste des processus . . . . .	14
1.2.3 Bilan matière du BSM1 . . . . .	16
1.2.4 Clarificateur . . . . .	17
1.2.5 Les influents . . . . .	18
1.2.6 Variables d'entrée et de sorties du Benchmark BSM1 . . . . .	19
1.3 Cas d'étude . . . . .	24
1.4 Conclusion: . . . . .	26
<b>CHAPITRE 2: ETAT DE L'ART SUR LE DIAGNOSTIC . . . . .</b>	<b>27</b>
2.1 Introduction . . . . .	27
2.2 Définitions et concepts . . . . .	28
2.3 Procédure de détection et d'isolation de défauts . . . . .	30
2.3.1 Différentes structures de défauts . . . . .	31
2.4 Classification des méthodes de diagnostic . . . . .	34
2.4.1 Méthodes avec modèles . . . . .	36
2.4.2 Méthodes sans modèles . . . . .	36
2.5 Conclusion: . . . . .	37
<b>CHAPITRE 3: DIAGNOSTIC À BASE D'ANALYSE DE DONNÉES STATISTIQUES MULTIVARIÉS . . . . .</b>	<b>38</b>
3.1 Introduction . . . . .	38
3.2 L'analyse en composantes principales . . . . .	38
3.3 Identification du modèle ACP . . . . .	40

3.4	Choix de la dimension de l'espace réduit et de nombre des CPs	42
3.4.1	Pourcentage cumulé de la variance (PCV) : . . . . .	42
3.4.2	Variance de l'erreur de reconstruction (VER) : . . . . .	43
3.4.3	Détection et localisation traditionnelles de défauts par ACP . . . . .	44
3.5	Localisation par ACP . . . . .	47
3.5.1	Localisation de défauts par calcul des contributions . .	47
3.5.2	Indice de validité des capteurs (SVI) : . . . . .	47
3.6	Extension non linéaire de l'ACP . . . . .	48
3.6.1	Analyse en composantes principale multi-échelle . . . .	49
3.6.2	ACP NL par réseaux de neurones auto-associatifs . . . .	52
3.7	Exemple d'illustration . . . . .	54
3.8	Conclusion: . . . . .	62

#### **CHAPITRE 4: CONTRIBUTION AU CONTRÔLE STATIS- TIQUE DES PROCESSUS NON LINÉAIRES 64**

4.1	Introduction . . . . .	64
4.2	Modèle de mélanges gaussiens . . . . .	66
4.3	Réseau EBNN . . . . .	69
4.4	Calcul du SPE . . . . .	72
4.4.1	Calcul des limites de contrôle locales basées sur KDE .	73
4.5	Calcul de la limite de contrôle adaptative (LCA) . . . . .	75
4.6	Isolation et identification par calcul des indices de validité des capteurs . . . . .	76
4.7	Conclusion . . . . .	78

#### **CHAPITRE 5: RÉSULTATS ET DISCUSSIONS . . . . . 79**

5.1	Introduction . . . . .	79
5.2	Test de simulation . . . . .	80
5.3	Détection de défauts capteurs . . . . .	85
5.4	Isolation et Identification des défauts capteurs par calcul de contributions . . . . .	91
5.5	Isolation par reconstruction de défauts capteurs . . . . .	92
5.6	Conclusion . . . . .	96

#### **CONCLUSION ET PERSPECTIVES . . . . . 97**

#### **BIBLIOGRAPHIE . . . . . 100**

## LISTE DES FIGURES

1.1	Schéma du Benchmark. . . . .	11
1.2	Equilibre massique autour des couches du décanteur secondaire, avec A est la surface de la couche. . . . .	18
1.3	Diagramme de simulation du BSM1. . . . .	24
1.4	Schéma de la station d'épuration des eaux usées d'Annaba. . . . .	25
2.1	Modélisation des défauts. . . . .	32
2.2	Classification des méthodes de diagnostic. . . . .	35
3.1	Cycle de surveillance de processus. . . . .	49
3.2	ACPNL par réseaux de neurones Auto-associatifs. . . . .	53
3.3	SPE dans des conditions normales calculé par la méthode l'ACP multi-modèles. . . . .	56
3.4	SPE dans des conditions normales utilisant un réseau AANN. . . . .	56
3.5	SPE filtré en fonctionnement normal en utilisant l'approche l'ACP multi-modèles. . . . .	57
3.6	SPE filtré en fonctionnement normal basé sur un réseau AANN. . . . .	57
3.7	SPE filtré avec défaut biais basé sur l'approche l'ACP multi- modèles. . . . .	58
3.8	SPE filtré avec défaut biais utilisant un réseau AANN. . . . .	58
3.9	SPE filtré avec défaut dérive utilisant la méthode l'ACP multi- modèles. . . . .	59
3.10	SPE filtré avec défaut dérive basé sur l'approche AANN. . . . .	60
3.11	Localisation du défaut biais par contribution à l'indice de dé- tection SPE calculé par la méthode l'ACP multi-modèles . . . . .	60
3.12	Localisation du défaut biais par contribution en utilisant un réseau AANN. . . . .	61
3.13	Localisation du défaut dérive par calcul de contributions basée sur l'ACP multi-modèles. . . . .	61
3.14	Localisation du défaut dérive par contribution basée l'approche AANN. . . . .	62
4.1	Cycle de surveillance de processus. . . . .	66
4.2	Structure BNN pour l'estimation et la classification des variables. . . . .	70
4.3	Reconstruction principe. . . . .	77
5.1	SPE sous fonctionnement normal (sans défaut) utilisant ACP Multi-Echelle sur les données du BSM1. . . . .	81

5.2	SPE des données réelles durant des conditions sous fonctionnement normal utilisant ACP Multi-Echelle. . . . .	81
5.3	SPE des données BSM1 utilisant AANN, sous fonctionnement normal. . . . .	82
5.4	SPE des données réelles de la station d'épuration d'Annaba, avec l'approche AANN durant des conditions de fonctionnement normal. . . . .	83
5.5	Évolution des concentrations $S_O, S_{NO}$ et $S_{ND}$ du BSM1 et leurs estimations après la normalisation. . . . .	83
5.6	Évolution des concentrations $S_O, S_{NO}$ et $S_{ND}$ de la station réelle et leurs estimations après la normalisation. . . . .	84
5.7	Taux de probabilités d'appartenance des variables du BSM1 par rapport aux modes de fonctionnement. . . . .	84
5.8	Taux de probabilités d'appartenance des variables par rapport aux modes de fonctionnement des données réelles. . . . .	85
5.9	SPE filtré durant un fonctionnement normal des données BSM1 avec une Limite de Contrôle Adaptative basée sur l'approche KDE. . . . .	86
5.10	SPE filtré pour des données réelles normales (sans défaut) avec une Limite de Contrôle Adaptative basée sur l'approche KDE. . . . .	86
5.11	SPE filtré pour une dégradation de précision dans le capteur $S_{NH}$ du BSM1. . . . .	88
5.12	SPE filtré pour une dégradation de précision dans le capteur $S_{NHinf}$ de la station d'épuration réel. . . . .	88
5.13	SPE filtré pour défaut biais affectant le capteur $S_O$ du BSM1. . . . .	89
5.14	SPE filtré d'un défaut biais affectant le capteur $S_{Oinf}$ de la station d'épuration réelle. . . . .	89
5.15	SPE filtré pour un défaut dérive en capteur $S_{NO2}$ du BSM1. . . . .	90
5.16	SPE filtré pour un défaut dérive affectant le capteur $N_{HAinf}$ de la station réelle. . . . .	90
5.17	Isolation par la méthode de contribution à l'indice de détection SPE pour un défaut dérive affectant le capteur $S_O$ du BSM1. . . . .	92
5.18	Contributions à l'indice SPE pour Isolation un défaut dérive affectant le capteur $S_{Oinf}$ de la station réelle. . . . .	93
5.19	Isolation par SVIs d'un défaut biais affectant un capteur $S_{NO1}$ du BSM1. . . . .	93
5.20	Isolation par SVIs d'un défaut biais affectant un capteur $S_{NOinf}$ de la station réelle. . . . .	94
5.21	Isolation par SVIs d'un défaut dérive affectant un capteur $S_{ND1}$ du BSM1. . . . .	94

5.22 Isolation par SVIs d'un défaut dérive affectant un capteur $S_{NO2inf}$ de la station réelle. . . . .	95
---	----

## LISTE DES TABLEAUX

1.1	Variables d'état du modèle de dégradation biologique . . . . .	15
1.2	Matrice des processus du modèle ASM1 . . . . .	22
1.3	Valeurs des paramètres stoechiométriques et des paramètres cinétiques du modèle ASM1 . . . . .	23
5.1	Les capteurs surveillés du BSM1. . . . .	79
5.2	Les capteurs surveillés du processus réel d'Annaba. . . . .	80
5.3	Scénarios des faults . . . . .	91



## NOTATIONS

ACP	Analyse en Composantes Principales.
ACPNL	Analyse en Composantes Principales non linéaire
ASM1	(Activated Sludge Model 1).
AANN	Auto-Associative Neural Network.
ANNC	Artificial Neural Network Classifier.
AUCL	Adaptive Upper Control Limit.
BSM1	Benchmark Simulation Model No. 1.
BNN	Bottleneck Neural Network.
$BDO_5$	Demande Biochimique en Oxygène.
CPs	Composantes Principales.
DCO	Demande Chimique en Oxygène.
EBNN	Enhanced Bottleneck Neural Network.
EP	Espace Principale.
ER	Espace Résiduel.
FDI	Détection et isolation de défauts (Faults Detection and Isolation)
EWMA	Exponentially Weighted Moving Average.
G	Centre de gravité.
IWA	International Water Association.
ITN	Input Training Network.
GMM	Gaussian Mixture Model.
KDE	Kernel Density Estimation.
LCA	Limite de Contrôle Adaptative
MES	Matières En Suspension.
MLP	Multi-Layer Perceptron.
MVS	Matières Volatiles en Suspension.
MSPC	Multivariate Statistical Process Control.
PCV	Pourcentage Cumulé de la Variance.
PRESS	Validation croisée.
RBF	Radial Basis Function.
RDN	Réseaux De Neurone artificiels.
SVI	Sensor Validity Index.
SPE	Squared Prediction Error SPE
SPM	Statistical Process Monitoring.
SPC	Statistical Process Control.
UCL	Upper Control Limit.
VER	Variance de l'Erreur de Reconstruction.
WWTP	Wastewater Treatment Plant.

$X \in \mathfrak{R}^{n \times m}$	matrice de données.
$n$	nombre d'observations mesurées.
$m$	nombre de variables à surveiller.
$\vartheta_{i=1\dots n}$	vecteurs observations (lignes de la matrice de données).
$v_{i=1\dots m}$	vecteurs variables (colonnes de la matrice de données).
$x_{ij}$	observation du vecteur variable.
$\bar{v}_j$	moyenne de la jème variable.
$\sigma_j^2$	variance de la jème variable.
$\Sigma \in \mathfrak{R}^{m \times m}$	matrice de covariance.
$P \in \mathfrak{R}^{m \times m}$	matrice de vecteurs propres de la matrice de corrélation.
$\lambda$	valeurs propres de la matrice de corrélation.
$\Lambda$	matrice diagonale des valeurs propres.
$T \in \mathfrak{R}^{n \times m}$	matrice de composantes principales.
$\ell < m$	dimension de l'espace réduit (nb de CPs retenues).
$\hat{P}$	$\ell$ premiers vecteurs propres.
$\tilde{P}$	$m - \ell$ derniers vecteurs propres.
$\hat{t}_j$	$\ell$ premières composantes principales de jème variable.
$\tilde{t}_j$	$m - \ell$ dernières composantes principales jème variable.
$\hat{X}$	matrice de données estimée par le modèle ACP.
$\tilde{X}$	matrice de données résiduelles.
$\hat{C}$	matrice représente le modèle ACP.
$z_j$	reconstruction de la jème variable.
$\xi_j$	jème colonne de la matrice unitaire (direction de défauts).
$\delta^2$	seuil de confiance de l'indicateur SPE.
$\eta_j^2(k)$	indice de validité des capteurs.

## INTRODUCTION GÉNÉRALE

Dans le domaine de traitement des eaux usées, l'efficacité recherchée en termes de qualité des effluents et d'économies des coûts de traitement a rendu nécessaire la modélisation, l'identification et la supervision des procédés de traitement biologiques d'épuration. La validation et la réconciliation des données est un thème qui regroupe les techniques appliquées lors de la conception d'un système mais aussi dans la phase d'exploitation de ce dernier.

Dans les processus en génie des procédés, en raison de leur caractère à risque, voire des risques environnementaux dans le cas des procédés biologiques d'épuration des eaux usées, si les défauts ne seront pas pris en compte, il y aura un risque d'avoir un grand impact sur l'évolution de ces systèmes [1–4]. Pour cette raison la sûreté de fonctionnement est devenue un véritable enjeu important, afin de garantir le bon fonctionnement en satisfaisant les performances correspondants à des conditions sous un mode de fonctionnement normal, la détection anticipée des anomalies de fonctionnement de ces systèmes, la nécessité d'améliorer la productivité, l'augmentation de la fiabilité et d'assurer la sécurité humaine et environnementale, de point de vue de l'Automatique sont des nécessités. En effet, c'est le principe de base du diagnostic d'état de fonctionnement des systèmes physiques qui permet de détecter, isoler et d'identifier toute sorte d'anomalies [5, 6].

Pour détecter la présence d'un défaut, le comportement du système est comparé à celui du modèle mathématique et tout écart significatif dénote une modification du comportement éventuellement explicable par la présence d'un défaut. La différence entre le comportement du système et celui du modèle est exprimée sous forme d'un résidu [5–10].

Le diagnostic est en effet, un processus comportant trois grandes fonctions : *la détection, l'isolation et l'identification* de défauts (un dysfonctionnement, une

anomalie au sein d'un processus, ...). Parmi les techniques de diagnostic mises en oeuvre actuellement et par la quelle nous nous sommes intéressés, sont les techniques à base d'analyse des données historiques du système à surveiller lors du fonctionnement normal basée sur les méthodes statistiques multi-variées.

Dans la littérature, plusieurs méthodes de surveillance et diagnostic à base d'outils statistiques multi-variées ont été largement utilisées dont le but d'améliorer la qualité de production et de renforcer la surveillance des systèmes. Parmi les méthodes les plus utilisées dans la surveillance et le diagnostic des systèmes par redondance analytique, l'Analyse en Composantes Principales (ACP) est la plus populaire de la famille statistique multivariée [5, 7]. Notre objectif dans cette thèse est le diagnostic de défauts provenant des capteurs. Traditionnellement, ces défauts sont considérés comme étant un changement au niveau de l'indice de détection [11–13].

L'objectif de cette thèse consiste à développer une approche robuste pour valider l'ensemble des informations délivrées par les capteurs utiles à la commande des processus complexes. Dans ce cas, les méthodes de supervisions visent d'une part à mieux connaître à chaque instant le mode de fonctionnement du système en question, et d'autre part (en cas de présence d'anomalie avérée ou de dérives par rapport au fonctionnement souhaité) à réagir sur les paramètres de contrôle. Cette thèse, présente une technique statistique multi-variée à base d'une nouvelle extension non linéaire de l'analyse en composantes principales basée sur un réseau de neurones artificiels sous forme de mémoires auto-associatives : réseau à cinq couches avec une couche d'étranglement amélioré en sa sortie (Enhanced Bottleneck Neural Network EBNN) pour modéliser une redondance analytique des informations délivrées par les capteurs disponibles dans les stations d'épuration. Dans le cadre de cette thèse, nous nous sommes intéressés par une proposition d'une nouvelle limite de contrôle qui consiste à générer une méthode robuste pour la détection de défauts

capteurs utilisant une Limite de Contrôle Adaptative (LCA) afin de minimiser les fausses alarmes et d'améliorer le temps de détection des défauts [14–16]. Dans la phase d'isolation et d'identification des défauts, notre objectif consiste à surmonter les inconvénients de la méthode traditionnelle basée sur le calcul de contributions. Pour cette raison, l'isolation de défaut et l'identification de sa nature par calcul des indices de validité des capteurs (Sensor Validity Indexes SVI) basé sur le principe de reconstruction (non linéaire) est utilisé [8, 17]. Pour tester l'efficacité de la stratégie proposée, des signaux artificiels d'un Benchmark d'une station d'épuration (Benchmark simulation model BSM1) ainsi des données réelles collectées de la station d'épuration d'Annaba ont été utilisées [4].

Ce travail est présenté en cinq chapitres :

**Le premier chapitre :** c'est un chapitre introductif dédié à présenter les concepts de base de traitement biologique des eaux usées. Deux descriptions des procédés de traitement biologiques des eaux usées ont été proposés, la première concerne un Benchmark d'une station d'épuration des eaux usées connu sous l'annotation anglaise Benchmark Simulation Model n°1 (BSM1) proposé par le groupe de recherches de l'association internationale des eaux (International Water Association IWA), ce modèle de simulation a été largement utilisé comme une plateforme de référence. La deuxième concerne une station réelle à boues activées située à Annaba dans l'est de l'Algérie.

**Le deuxième chapitre :** ce chapitre est consacré à un état de l'art sur les méthodes du diagnostic généralement utilisées dans la littérature. En effet nous allons rappeler quelques définitions et exposer un panorama assez complet des principes généraux du diagnostic des systèmes. Les techniques décrites dans ce travail sont les plus connues et les plus couramment utilisées.

**Le troisième chapitre :** dans ce chapitre nous abordons une synthèse bibliographique des méthodes du diagnostic basées sur l'analyse des données statistiques

multivariées généralement utilisées dans la littérature, en l'occurrence l'Analyse en Composante Principale (ACP) ainsi ses extensions non linéaires tel que l'ACP multi-échelles et celle basée sur un réseau de neurones à cinq couches avec une couche d'étranglement.

**Le quatrième chapitre :** ce chapitre est consacré à la contribution de cette thèse dans lequel nous présentons la nouvelle stratégie du diagnostic à base d'analyse des données statistiques multi-variées dont le but de générer une limite de contrôle adaptative. En utilisant dans un premier temps un algorithme GMM (Gaussian Mixture Modes) pour extraire des différents modes de fonctionnements des variables (mesures des capteurs) à surveiller collectées dans des conditions de fonctionnement normal, ces variables seront estimées par le réseau de neurones avec couche d'étranglement amélioré en sa sortie ( Enhanced Bottleneck Neural Network EBNN), ce réseau permet aussi d'effectuer une classification supervisée des variables à surveiller selon leurs taux d'appartenance aux modes de fonctionnements déjà extraits par l'algorithme GMM, où chaque mode sera représenté par des distributions gaussiennes multiples.

**Le cinquième chapitre :** ce chapitre consiste à présenter les discussions et les résultat de simulation obtenus à partir d'une application de la stratégie proposée dans le quatrième chapitre dont le but de détecter, isoler et identifier des défauts provenant des capteurs, dans un premier temps nous appliquons l'algorithme du diagnostic sur des données artificielles du BSM1 puis sur des données réelles pour tester l'efficacité de l'algorithme en analysant les avantages et les limites de ces outils et en motivant l'utilisation de la stratégie à base du réseau EBNN proposée.

Enfin, ce manuscrit présente une conclusions générale.

## CHAPITRE 1

### DESCRIPTION DES PROCÉDÉS DU TRAITEMENT DES EAUX USÉES

#### 1.1 Introduction

Les eaux usées sont toutes les eaux qui sont de nature à contaminer les milieux dans lesquelles elles sont déversées. On classe généralement les eaux usées selon leur provenance et leurs caractéristiques en :

Eaux usées urbaines : La pollution urbaine provient principalement des différents usages domestiques de l'eau. On trouve les eaux des toilettes chargées en matières organiques et azotées, les eaux ménagères provenant des salles de bains, des cuisines et des eaux de lavages, chargées en détergents, graisses, solvants et débris organiques. A ceux-ci, s'ajoutent les rejets des petites industries, des commerces et de l'artisanat, et enfin les eaux pluviales susceptibles de lessiver les toits et les bitumes chargés en hydrocarbures et graisses.

Eaux usées industrielles : Les eaux usées industrielles résultent principalement des industries agro-alimentaires, papetières, chimiques, textiles, des cuirs et des peaux, des industries extractives, des industries minérales, mécaniques et de traitement de surfaces, de production d'énergie, des industries sidérurgiques et métallurgiques.

Leurs caractéristiques varient d'une industrie à l'autre. L'industrie est responsable d'une grande partie des rejets polluants organiques, azotés ou phosphorés. Certaines d'entre elles doivent faire l'objet d'un prétraitement de la part des industriels avant d'être rejetées dans les réseaux de collecte. Les eaux polluées sont des eaux contaminées avec des produits de nature organique, minérale ou métallique. On parle de pollution lorsque la présence de ces produits dans un milieu



entraîne sa modification. Les substances polluantes sont également classées selon leur toxicité et leur impact sur la faune et la flore. Au premier rang (en termes de quantités), les éléments polluants riches en carbone, azote constituent la pollution la plus abondante. Ces substances n'ont pas d'effet toxique direct sur les êtres vivants. Toutefois, à forte concentration, elles peuvent s'avérer dangereuses pour les écosystèmes.

La pollution organique riche en carbone et azote existe sous forme de plusieurs molécules. Pour pouvoir les caractériser, des unités de mesure ont été adoptées pour chaque composant. Les molécules carbonées représentent la plus grande partie de la pollution. On mesure la pollution carbonée par la Demande Chimique en Oxygène (DCO). C'est la quantité d'oxygène nécessaire pour oxyder chimiquement une quantité de matière organique donnée [18]. La DCO est l'unité de mesure de pollution carbonée la plus utilisée en modélisation des procédés biologiques car elle permet de faire des bilans de matière regroupant des produits organiques biodégradables et non biodégradables. La pollution azotée vient au second rang après la pollution carbonée. Cet élément, s'il est organique, est caractérisé par la mesure de l'Azote Kjeldal (NTK). Cette mesure donne la masse d'azote contenue dans les différentes molécules organiques. Sinon, s'il est sous forme ionique simple : Azote Ammoniacal  $NH_4^+$  , Nitrite  $NO_2^-$  , ou Nitrate  $NO_3^-$  , il est mesuré par la masse contenue dans ces ions.

Un autre élément très important à évaluer est la quantité de matières en suspension présente dans l'eau. Les matières en suspension sont de nature organique ou minérale. Pour les caractériser, deux mesures sont utilisées : Les Matières En Suspension (MES) : Dans le traitement biologique par boues activées, cette mesure représente la masse de toutes les matières solides (non dissoutes) contenues dans l'eau. Les Matières Volatiles en Suspension (MVS) : cette mesure donne la masse de matière organique présente dans les MES. La différence avec les MES représente la matière minérale. Très souvent, la quantité de biomasse (par définition solide

et composée de matière organique) est assimilée à la mesure de MVS. L'élément déclencheur d'une réaction biologique est la présence de micro-organismes dans un environnement favorable à leur croissance. Pour permettre le bon fonctionnement de son métabolisme et assurer sa croissance, une cellule bactérienne a besoin principalement d'une source d'énergie et d'une source de carbone. D'autres éléments chimiques comme l'oxygène, l'azote et l'hydrogène sont nécessaires pour la croissance cellulaire et sont assimilés lors de la biosynthèse [19].

D'une manière générale, on distingue deux sources d'énergie pour les êtres vivants :

l'énergie lumineuse (plantes et bactéries phototrophes) et l'énergie chimique (animaux et bactéries chimiotrophes). Les bactéries chimiotrophes tirent leur énergie de la dégradation des molécules organiques complexes. Dans un premier temps, les molécules complexes sont dégradées par hydrolyse en molécules plus petites susceptibles d'entrer dans la cellule. Les étapes de dégradation successives en molécules simples à l'intérieur des micro-organismes permettent une libération d'énergie et la production de pouvoir réducteur. L'énergie libérée est utilisée pour effectuer des réactions de biosynthèse ou est stockée sous forme de liaisons chimiques riches en énergies comme la liaison phosphate de l'ATP. Le devenir des molécules simples va dépendre du type de micro-organismes et de la présence ou non d'oxygène dans le milieu. Les réactions chimiques qui sont mises en oeuvre par la suite sont soit des réactions d'oxydation, soit des réactions de fermentation [19]. Au cours de la réaction d'oxydation (appelée également respiration), les molécules organiques (donneurs d'électrons) perdent des électrons qui vont être captés par d'autres molécules (accepteurs d'électrons). Cette réaction est réalisée en présence de bactéries aérobies. On distingue deux familles de bactéries aérobies : les Hétérotrophes  $X_{B,H}$  et les Autotrophes  $X_{B,A}$ .

Les bactéries hétérotrophes utilisent le carbone organique, à la fois comme source d'énergie et comme source de carbone. Dans des conditions particulières, cer-

taines bactéries hétérotrophes remplacent l'oxygène par des oxydants moins forts comme  $NO_3^-$  et leurs produits réduits lors de l'oxydation. Par contre, les bactéries Autotrophes utilisent le dioxyde de carbone  $CO_2$  comme source de carbone.

Du point de vue de l'automatique, les procédés de traitement des eaux usées sont des systèmes non linéaires complexes de grande dimension. Ces derniers sont soumis à d'importantes perturbations sur le flux d'effluent et la charge de polluant, en plus des incertitudes concernant la composition de l'eau usée entrante. Ces procédés doivent fonctionner de manière continue, ce qui exige des régulations de certaines variables à des consignes désirées, et le rejet des effets des perturbations. Plusieurs stratégies de commande ont été proposées pour la commande d'un procédé de traitement des eaux usées, mais leur comparaison ou l'évaluation des performances de chaque stratégie, par simulation ou pratiquement, est difficile. Les difficultés sont dues à plusieurs raisons :

la variabilité de l'influent, les variations des débits et des compositions d'entrée, la complexité des phénomènes biologiques et biochimiques d'où la difficulté de modélisation, le procédé est caractérisé par des constantes de temps d'ordres de grandeur très différents variant de quelques minutes à plusieurs jours, l'absence de critères standard pour l'évaluation des performances, la complexité du modèle du procédé qui est multivariable et non linéaire rend le problème de synthèse d'un système de commande très difficile.

### 1.1.1 Principes généraux de traitement des eaux usées

Le traitement des eaux usées est réalisé dans les stations d'épuration. La plupart des stations d'épuration fonctionnent selon les mêmes processus de base, mais des différences plus ou moins importantes peuvent exister dans la manière de mettre en place ces processus. Le traitement se divise généralement en plusieurs étapes.

### 1.1.2 Pré-traitement

Il consiste en trois étapes principales et permet de supprimer de l'eau les éléments qui gêneraient les phases suivantes de traitement. Ces étapes sont :

**Dégrillage et tamisage** : Cette étape permet de retirer de l'eau les déchets insolubles (les branches, les plastiques et serviettes hygiéniques...). On parle d'une élimination mécanique, car ces déchets ne peuvent pas être éliminés par un traitement biologique ou physico-chimique. Par conséquent, l'eau usée traverse une ou plusieurs grilles dont les mailles sont de plus en plus serrées.

**Dessablage** : Par décantation, cette étape permet de retirer les sables mélangés dans les eaux par ruissellement ou amenés par l'érosion des canalisations. Cette étape est importante pour éviter une usure prématurée des éléments mécaniques tels que les pompes.

**Dégraissage** : Dans cette étape, le principe de la flottation est utilisé pour l'élimination des huiles. Il est basé sur l'injection de fines bulles d'air dans le bassin de déshuilage, et comme les graisses sont hydrophobes, elles remontent rapidement en surface et sont éliminées par raclage de la surface.

### 1.1.3 Traitement par voie biologique

Une décantation primaire a lieu avant que les eaux usées soient traitées par la voie biologique. Cette décantation permet de supprimer une grande partie des matières en suspension qui sont responsables du trouble des eaux usées. La voie biologique est la plus utilisée pour l'épuration des eaux usées contenant des polluants biodégradables de nature organique ou chimique. Les procédés de traitement des eaux usées ont pour principe de mettre en contact des micro-organismes et les polluants dans des enceintes (réacteurs) dont il est possible de contrôler les conditions environnementales [20]. Les réactions biologiques font intervenir trois entités essentielles qu'il est important de distinguer : La biomasse regroupe des micro-

organismes qui participent aux chaînes de dégradation. Les substrats sont les composants nutritifs qui sont dégradés par les microorganismes. Les produits sont les composants résultant de la dégradation des substrats par les micro-organismes. À noter que lorsque plusieurs réactions s'enchaînent, le produit d'une réaction peut être considéré comme le substrat d'une autre. Les biomasses peuvent être considérées comme faisant partie de la phase solide. Les substrats et les produits sont majoritairement présents en phase liquide ou gazeuse. Les procédés biologiques de traitement des eaux transfèrent la pollution d'une forme liquide et la concentrent sous une forme solide. La biomasse (forme solide) est séparée de la phase liquide par décantation (phénomène physique) et le surnageant dépollué est rejeté dans le milieu naturel. Dans certains cas, la séparation solide-liquide est améliorée ou accélérée par centrifugation, filtration par membrane ou par ajout de coagulants. L'excès de biomasse, produit de la croissance cellulaire, est retiré. En d'autres termes, les procédés biologiques de traitement des eaux usées transfèrent la pollution d'une forme liquide et la concentrent sous une forme solide.

Les eaux usées contiennent notamment du carbone, de l'azote et du soufre sous diverses formes de composés qui peuvent être traités chimiquement par divers procédés. Tous les traitements physico-chimiques consistent à séparer les composés de ces éléments d'une phase liquide pour les concentrer dans une autre phase. Ce sont notamment les procédés de strippage (élimination de gaz dans l'eau au moyen d'un gaz d'entraînement), d'osmose inverse, de distillation, de précipitation chimique ou d'oxydation catalytique dont les coûts de mise en oeuvre et d'exploitation sont élevés. L'élimination par voie biologique de ces composés constitue une solution différente et intéressante de traitement.

#### **1.1.4 Traitement du carbone et de l'azote**

Le carbone est un élément polluant qui peut être traité seul (au sens où son traitement nécessite une seule condition environnementale). En revanche, le pro-

cessus d'élimination de l'azote nécessite plusieurs étapes (plusieurs conditions environnementales). Au début de l'année 80, [21] a posé les bases fondamentales pour l'élimination de l'azote. Par la suite, les efforts pour fédérer la connaissance pour une mise en oeuvre pratique du traitement simultané du carbone et de l'azote ont été réalisés au travers de la production d'un rapport de l'International Association on Water Pollution Research and Control (IAWPRC) [22].

## 1.2 Benchmark Simulation Model 1 (BSM1)




FIGURE 1.1 – Schéma du Benchmark.

Les installations d'épuration des eaux usées sont des systèmes de grande dimension, non linéaires et sujets à des variations importantes en flux (débit) et en charge. Plusieurs stratégies de commande ont été proposées dans la littérature mais leur évaluation et comparaison restent une tâche difficile à réaliser. Cela est dû à plusieurs facteurs : La variabilité des eaux usées à traiter, la complexité des réactions biologiques et mises en jeu, la variation de temps de réponse (le comportement hydrodynamique) et le manque de critères standards d'évaluation [23]. Toutefois, un modèle de référence comme le simulateur Benchmark rend possible l'évaluation de la performance des différentes stratégies de commandes avancées dans le traitement

des eaux usées à partir des simulations [24]. L'utilisation du Benchmark sert notamment pour l'estimation de la performance du procédé, l'évaluation d'algorithmes ou de stratégies qui sont développés dans la communauté scientifique. Le succès du BSM1 (Benchmark Simulation Model 1) de l'IWA/COST est attesté par plusieurs publications scientifiques dans le domaine des eaux usées [25].

Ce Benchmark a été développé par des chercheurs des groupes de travail du programme COST (European Cooperation in the field of Scientific and Technical Research) 682 et 624 (de 1998 à 2004) qui ont regroupé leurs connaissances dans ce domaine. Actuellement, le groupe de l'IWA continue à développer ce Benchmark. Le Benchmark est un environnement de simulation qui définit une installation d'épuration, un modèle de simulation et l'ensemble des paramètres du modèle, les caractéristiques des eaux usées, les tests de protocoles et les critères d'évaluation [26]. Le BSM1 combine les processus de nitrification avec dénitrification fréquemment appliqués dans la dégradation biologique de l'azote. La configuration standardisée de l'installation de traitement par boues activées utilisée dans le Benchmark est constituée d'un réacteur biologique et d'un décanteur secondaire, voire figure 1.1.

Le réacteur biologique est composé de cinq compartiments parfaitement agités où les deux premiers sont maintenus en anoxie (volume de chacun  $1000\text{ m}^3$ ) et les trois derniers en aérobie (volume de chacun  $1333\text{ m}^3$ ), ce qui donne comme volume total du réacteur  $6000\text{ m}^3$ . Le décanteur secondaire est représenté comme un système non réactif et unidimensionnel divisé en 10 couches horizontales, selon le modèle de vitesse de décantation exponentielle double proposé par [27]. Son volume total est égal à  $6000\text{ m}^3$ .

Les eaux usées subissent d'abord un traitement anoxique (unités 1 et 2) par voie biologique en cultures libres selon lequel, dans une première étape, le carbone organique (DCO) est essentiellement éliminé par des bactéries hétérotrophes. L'effluent sortant de la première étape est soumis à un traitement biologique aérobie en cultures libres pour la transformation de l'ammonium en nitrates. Une frac-

tion de l'effluent qui a subi le traitement biologique aérobie et qui contient des nitrates, est renvoyée vers la première étape du traitement anoxique pour éliminer l'azote. Le Benchmark utilise le modèle ASM1 (Activated Sludge Model 1) pour la prédiction des phénomènes biologiques dans le réacteur. Le modèle ASM1 simule au sein d'un système à boues activées les phénomènes tels que l'oxydation du carbone, la nitrification et la dénitrification en quantifiant la cinétique et la stoechiométrie de chaque réaction. Il a été présenté [28], afin de formaliser les différentes connaissances accumulées pendant la vingtaine d'années précédentes sur la modélisation mathématique du traitement des eaux usées par voie biologique. Le modèle ASM1 [28] constitue un modèle général capable de représenter de façon précise le comportement du procédé lors du traitement d'un effluent chargé en matières azotées et carbonées. A ce niveau, le modèle comporte 13 variables d'état (liées aux phénomènes biologiques), 8 processus et 19 différents paramètres cinétiques et stoechiométriques.

### 1.2.1 Variables d'état

L'ensemble des réactions décrites lors de la présentation du schéma réactionnel est pris en compte dans ce modèle :

- la croissance de la biomasse au travers de la réaction d'oxydation de la matière carbonée et des réactions de nitrification et de dénitrification ;
- la mort de la biomasse ;
- l'ammonification de l'azote organique ;
- l'hydrolyse de la matière organique en suspension (azotée ou carbonée).

L'hydrolyse représentant un ensemble de réactions complexes, une unique expression globale a été proposée afin de simplifier sa modélisation. Cette modélisation suppose que seule la partie rapidement biodégradable de la matière organique biodégradable peut être utilisée par la biomasse. L'expression de l'hydrolyse per-



met donc d'introduire une dynamique lente pour l'utilisation de la partie lentement biodégradable.

Ces phénomènes biologiques font appel à différents types de composés représentés par treize variables d'état. La lettre  $X$  est proposée pour les composés particuliers et la lettre  $S$  pour les composés solubles. Nous pouvons classer ces variables d'état en cinq groupes :

- les substrats : le substrat rapidement biodégradable  $S_S(mg_{O_2}.l^{-1})$  et le substrat lentement biodégradable  $X_S(mg_{O_2}.l^{-1})$ .
- les biomasses : la biomasse hétérotrophe  $X_{BH}(mg_{O_2}.l^{-1})$ , responsable de l'oxydation des matières organiques et de la dénitrification, et la biomasse autotrophe  $X_{BA}(mg_{O_2}.l^{-1})$ , responsable de la nitrification. La croissance des biomasses est décrite par la loi de Monod. Une troisième variable d'état, notée  $X_P(mg_{O_2}.l^{-1})$ , représente les produits issus de la mort de la biomasse ;
- les composés azotés : l'azote organique biodégradable particulaire  $X_{ND}(mg_N.l^{-1})$ , l'azote organique biodégradable soluble  $S_{ND}(mg_N.l^{-1})$ , l'azote ammoniacal  $S_{NH}(mg_N.l^{-1})$  et les nitrates-nitrites  $S_{NO}(mg_N.l^{-1})$  ;
- l'oxygène dissous  $S_O(mg_{O_2}.l^{-1})$  ;
- les états biologiquement inertes : les composés organiques inertes solubles  $S_I(mg_{O_2}.l^{-1})$  et particuliers  $X_I(mg_{O_2}.l^{-1})$ , l'alcalinité  $S_{alk}(mol.l^{-1})$ .

### 1.2.2 La liste des processus

Les équations du modèle sont présentées sous forme d'une matrice (tableau 1.1). La première ligne de cette matrice contient les variables d'état du modèle. La première colonne indique le nom des cinétiques biologiques dont l'expression est donnée dans la dernière colonne. Dans chaque case  $(i, j)$ , le taux de conversion  $Y_{i,j}$  apparaît. Pour chaque réaction biologique, les vitesses de consommation et de

TABLE 1.1 – Variables d'état du modèle de dégradation biologique

N	Composée	Symbole	Unité
1	Matière organique soluble inerte	$S_I$	$mg_{O_2}.l^{-1}$
2	Substrat facilement biodégradable	$S_S$	$mg_{O_2}.l^{-1}$
3	Matière organique particulaire inerte	$X_I$	$mg_{O_2}.l^{-1}$
4	Substrat lentement biodégradable	$X_S$	$mg_{O_2}.l^{-1}$
5	Biomasse activées hétérotrophe	$X_{B,H}$	$mg_{O_2}.l^{-1}$
6	Biomasse activées autotrophe	$X_{B,A}$	$mg_{O_2}.l^{-1}$
7	Azote sous forme de nitrites et nitrates	$S_N$ ,	$mg_N.l^{-1}$
8	Azote sous forme d'ammoniaque	$S_{NH}$	$mg_N.l^{-1}$
9	Azote organique soluble biodégradable	$S_{ND}$	$mg_N.l^{-1}$
10	Azote organique particulaire biodégradable	$X_{ND}$	$mg_N.l^{-1}$
11	Oxygène dissous	$S_O$	$mg_{O_2}.l^{-1}$

production des composés impliqués sont données par le produit  $Y\rho$ , précédé respectivement du signe  $(-)$  s'il y a consommation et du signe  $(+)$  s'il y a production. L'ensemble des vitesses agissant sur le composé  $j$  est appelé la vitesse biologique globale, notée  $r_j$ , et est donc décrite par la colonne associée qui indique l'ensemble des réactions intervenant sur cette variable d'état. Son expression est :

$$r_j = \sum Y_{i,j}\rho_{ij} \quad (1.1)$$

Le tableau présente les valeurs des paramètres stoechiométriques et cinétiques suggérées par le groupe de l'IWA. Ces valeurs sont données à titre indicatif et peuvent varier en fonction des conditions environnementales. La sélection des valeurs pour les coefficients stoechiométriques et cinétiques d'un modèle mathématique est la phase de calibration du modèle. Dans le cas des modèles des boues activées, la calibration est réalisée à partir d'expériences spécifiques et bien contrôlées dans des réacteurs de laboratoire dans des conditions définies.

### 1.2.3 Bilan matière du BSM1

Cinq réacteurs en série sont considérés et indicés par  $k$ . Pour  $k = 1$  (premier réacteur)

$$\frac{dZ_{1,i}}{dt} = \frac{1}{V_1}(Q_a Z_{a,i} + Q_r Z_{r,i} + Q_0 Z_{0,i} - Q_1 Z_{1,i} + r_i V_1) \quad (1.2)$$

avec :

$V_1$  : Volume du premier réacteur,

$Q_a$  : Débit de recyclage interne,

$Z_{a,i}$  : Concentration du composant  $i$  en sortie du cinquième réacteur,

$Q_r$  : Débit de recyclage externe,

$Z_{r,i}$  : Concentration du composant  $i$  en sortie du clarificateur,

$Q_0$  : Débit entrant des effluents,

$Z_{0,i}$  : Concentration initiale du composant  $i$  dans l'effluent d'entrée.

$Q_1$  : Débit sortant du premier réacteur,

$Z_{1,i}$  : Concentration du composant  $i$  à l'intérieur du réacteur, cette concentration est la même en tout point du réacteur (réacteur homogène et parfaitement agité),

$r_i$  : Vitesse biologique globale du composant  $i$  (variable d'état  $i$ ). Le processus de croissance ou de disparition des composants est proportionnel au volume du réacteur.

Dans chaque réacteur, le volume est constant, donc le débit d'entrée est égal au débit de sortie :

$$Q_k = Q_{k-1}$$

Pour  $k = 1, 2, 3, 4, 5$

$$\frac{dZ_{1,i}}{dt} = \frac{1}{V_k}(Q_{k-1} Z_{k-1,i} - Q_k Z_{k,i} + r_i V_k) \quad (1.3)$$

Cas spécial de l'oxygène dissout ( $S_O$ ) :

$$\frac{dS_{O_k}}{dt} = \frac{1}{V_k} (Q_{k-1}S_{O_{k-1}} - Q_k S_{O_k} + r_i V_k + (k_{la})_k V_k (S_O^* - S_{O_k})) \quad (1.4)$$

avec  $k_{la}$  le coefficient de transfert gaz-liquide pour l'oxygène et  $S_O^*$  la concentration de saturation d'oxygène dans l'eau et en présence de biomasse, égal à  $8mg.l^{-1}$ .

#### 1.2.4 Clarificateur

Après le traitement biologique, l'effluent est dirigé vers le clarificateur (ou décanteur secondaire) pour séparer l'eau à traiter de la biomasse en suspension. La croissance de la biomasse au sein des bioréacteurs n'est pas suffisante pour compenser la perte engendrée par le débit de sortie  $Q_f$  du dernier réacteur aérobie (unité 5). Pour conserver une concentration en biomasse constante dans les réacteurs, une partie des boues du clarificateur est recyclée vers le premier réacteur anoxie (unité 1). Une faible concentration de biomasse est extraite et subira un traitement spécifique, avec les boues issues du traitement primaire. Le décanteur secondaire est représenté comme un système non réactif et unidimensionnel divisé en 10 couches horizontales, selon le modèle de vitesse de décantation exponentielle double proposé par [27]

$$V_s(X) = V_{max}(e^{-r_h(X-X_{min})} - e^{-r_p(X-X_{min})}) \quad (1.5)$$

avec,

$V_s$  : vitesse de décantation (m.h-1),

$V_{max}$  : vitesse maximum de décantation de Vesilind ( $m.h^{-1}$ ),

$r_h$  : coefficient associé à la décantation ( $m^3.gMES^{-1}$ ),

$X$  : concentration en  $MES$ ,

$X_{min}$  : concentration en *MES* minimale au-dessous de laquelle il n'y a plus de décantation possible,

$r_p$  : coefficient associé à la séparation de phase ( $m^3.gMES^{-1}$ ).

Ce modèle est basé sur le concept du flux matière : un bilan massique est calculé dans chaque couche. Cinq groupes différents de couches, selon leur position par rapport au point d'arrivée des effluents dans le décanteur (6<sup>me</sup> couche), ont une contribution particulière dans le bilan de matière. Le flux de matières dû au mouvement du volume liquide peut être dirigé vers le haut ou vers le bas selon sa position par rapport à la couche d'alimentation. Ceci est montré schématiquement sur la figure 1.2.

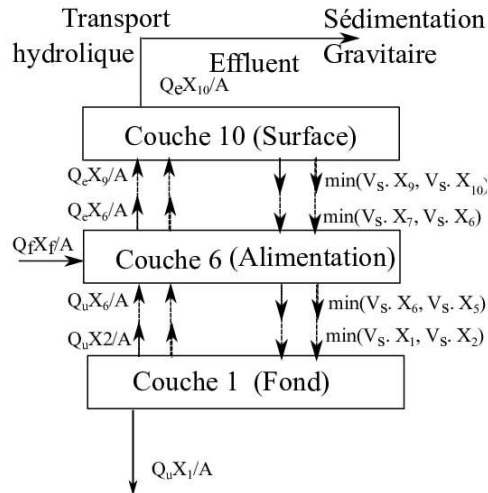


FIGURE 1.2 – Equilibre massique autour des couches du décanteur secondaire, avec  $A$  est la surface de la couche.

A la sortie des clarificateurs, un traitement physico-chimique est réalisé pour éliminer les phosphates avant que l'effluent ne soit rejeté dans le milieu naturel.

### 1.2.5 Les influents

Les influents n'ont pas un flux constant et uniforme au cours de la journée. Les eaux usées présentent un comportement très variable, qui peut changer d'une

heure à l'autre sous l'effet de plusieurs facteurs externes. La variabilité des eaux usées peut être due aux fluctuations en débit  $Q_0$  et en concentration  $Z_0$  selon des périodicités journalières, hebdomadaires et saisonnières.

La variabilité du débit et de la composition des eaux usées est liée également à des caractéristiques météorologiques, comme les évènements pluvieux ou orageux qui peuvent entraîner une augmentation de débit. Pour cela, face à cette augmentation de débit, les stations d'épuration sont équipées par des bassins d'orage pour stocker les eaux de pluie. Un atout important du Benchmark BSM1 réside dans les fichiers permettant de représenter les variations en fonction du temps des variables décrivant la composition de l'eau usée entrant dans le système ainsi que son débit. Trois fichiers (temps sec, temps pluvieux et orage), d'une durée de deux semaines, ont été bâtis à partir des diverses données et ne sont pas spécifiques d'un site particulier. Compte tenu du fait que l'installation représentée dans BSM1 se limite à l'étage biologique, ces fichiers décrivent une eau usée après une décantation primaire. Les détails de la construction de ces fichiers sont décrits par (Vanhooren and Nguyen, 1996). Les effluents dans ces fichiers sont donnés dans l'ordre suivant :  $S_I, S_S, X_I, X_S, X_{B,H}, X_{B,A}, X_P, S_O, S_{NO}, S_{NH}, S_{ND}, X_{ND}, S_{ALK}, Q_0$ .

La valeur de  $S_O$  est nulle à l'entrée du réacteur biologique. Pour cela, dans les réacteurs, on apporte l'oxygène suffisant ( $S_O$ ). Une agitation permanente a lieu dans chaque réacteur afin de favoriser le contact entre bactéries et pollution et d'avoir une concentration élevée en bactéries pour augmenter l'efficacité du traitement.

### 1.2.6 Variables d'entrée et de sorties du Benchmark BSM1

De manière générale, pour un système dans l'espace d'état, on distingue trois types de variables : entrées, états et sorties. Les variables d'entrée agissent sur le système et peuvent être classées en entrée manipulées et en perturbations. Les variables d'état décrivent l'évolution du système, donc le contenu des bassins (systèmes de traitement). Les états sont calculés à partir des équations algébriques et

différentielles de bilans, connaissant les variables d'entrée. Les variables de sortie décrivent l'effluent sortant et la boue extraite et sont calculées à partir des variables d'état.

**Variables d'entrée :**

$q_a$  : débit de recyclage interne ( $m^3.h^{-1}$ ),

$q_r$  : débit de recyclage externe ( $m^3.h^{-1}$ ),

$q_w$  : débit de rejet ( $m^3.h^{-1}$ ),

$k_{la3}$  : coefficient de transfert de matière d'oxygène 3<sup>me</sup> unité ( $h^{-1}$ ),

$k_{la4}$  : coefficient de transfert de matière d'oxygène 4<sup>me</sup> unité ( $h^{-1}$ ),

$k_{la5}$  : coefficient de transfert de matière d'oxygène 5<sup>me</sup> unité ( $h^{-1}$ ),

$q_{2in}$  : débit d'ajout en source carbonée ( $m^3.h^{-1}$ ),

**Variables de sortie :**

$DCO$  (Demande Chimique en Oxygène en  $mg.l^{-1}$ ) :

$$S_S + S_I + X_S + X_I + X_{B,H} + X_{B,A} + X_P$$

$BDO_5$  (Demande Biochimique en Oxygène à 5 jours en  $mg.l^{-1}$ ) :

$$0.65(S_S + X_S + (1 - f_p).(X_{B,H} + X_{B,A}))$$

$[S_S]$  (Solides en suspension en  $mg.l^{-1}$ ) :

$$0.75(X_S + X_I + X_{B,H} + X_{B,A} + X_P)$$

$[N_H]$  (Azote en  $mg.l^{-1}$ ) :

$$S_{NH} + S_{ND} + X_{ND} + i_{XB}(X_{B,H} + X_{B,A}) + i_{XP}(X_P + X_I)$$

$[N]_{tot}$  (Nitrogène total en  $mg.l^{-1}$ ) :

$$[N_H] + S_{NO}$$

Les valeurs numériques des coefficients stchiométriques  $f_p$ ,  $i_{XB}$  et  $i_{XP}$  se trouvent dans le tableau 1.3

La  $DCO$  (Demande Chimique en Oxygène) ne donne qu'une indication de la possible oxydation de la matière organique carbonée (biodégradables et inertes). La  $DCO$  est une analyse qui quantifie la pollution totale dans un échantillon d'eau

usée, sans faire de distinction entre ses composantes biodégradables et inertes.

La  $BDO_5$  (Demande Biochimique en Oxygène à 5 jours) traduit la quantité d'oxygène nécessaire pour dégrader les molécules carbonées (La matière organique carbonée utilisée par les micro-organismes hétérotrophes).



TABLE 1.2 – Matrice des processus du modèle ASM1

i	Concentrations $j$ Réaction $\rho_i$	1 $S_i$	2 $S_s$	3 $X_i$	4 $X_s$	5 $X_{BH}$	6 $X_{BA}$	7 $X_p$	8 $S_O$	...
1	Croissance aérobie des hétérotrophes		$-\frac{1}{Y_H}$			1			$-\frac{1-Y_H}{Y_H}$	...
2	Croissance aérobie des anoxique		$-\frac{1}{Y_H}$			1				...
3	Croissance autotrophe aérobie						1		$-\frac{4.75-Y_A}{Y_A}$	...
4	Mortalité des hétérotrophes				$1 - f_p$	-1		$f_p$		...
5	Mortalité des autotrophes				$1 - f_p$		-1	$f_p$		...
6	Ammonification									...
7	Hydrolyse du carbone organique		1		-1					...
8	Hydrolyse de l'azote organique									...

...	9 $S_{NO}$	10 $S_{NH}$	11 $S_{ND}$	12 $X_{ND}$	13 $S_{alk}$	Céinitique de la réaction
...		$-i_{XB}$			$-\frac{i_{XB}}{14}$	$\hat{\mu}_H \frac{S_s}{K_S+S_S} \frac{S_O}{K_{OH}+S_O}$
...	$-\frac{1-Y_H}{2.68Y_H}$	$-i_{XB}$			$-\frac{1-Y_H}{14 \times 2.68Y_H} - \frac{i_{XB}}{14}$	$\frac{S_{NO}}{K_{NO}+S_{NO}} \eta_g X_{B,H}$
...	$\frac{1}{Y_A}$	$-i_{XB} - \frac{1}{Y_A}$			$-\frac{i_{XB}}{14} - \frac{1}{7Y_A}$	$\hat{\mu}_A \frac{S_{NH}}{K_{NH}+S_{NH}} \frac{S_O}{K_{OA}+S_O} X_{B,A}$
...				$i_{XB} - f_p i_{Xp}$		$b_H X_{B,H}$
...				$i_{XB} - f_p i_{Xp}$		$b_A X_{B,A}$
...		1	-1		$\frac{1}{14}$	$K_a S_{ND} X_{B,H}$
...			1	-1		$K_h \frac{X_s/X_{B,H}}{K_X X_s/X_{B,H}} \left[ \left( \frac{S_O}{K_{OH}+S_O} \right) + \eta_h \left( \frac{K_0 H}{K_{OH}+S_O} \right) \left( \frac{S_{NO}}{K_{NO}+S_{NO}} \right) \right] X_{B,H}$
...						$\rho_T \frac{X_{ND}}{X_S}$

TABLE 1.3 – Valeurs des paramètres stoechiométriques et des paramètres cinétiques du modèle ASM1

<b>Coefficients stoechiométriques</b>	Notation	Valeur	Unité
Taux de conversion substrat / biomasse autotrophe	$Y_A$	0.24	$go_2X_{ba}gN^{-1}$
Taux de conversion substrat / biomasse hétérotrophe	$Y_H$	0.67	$go_2X_{bh}go_2S_s^{-1}$
Fraction de DCO inertes générés par la biomasse morte	$f_p$	0.08	-
Fraction d'azote dans la biomasse hétérotrophe	$i_{XB}$	0.08	$gN.go_2^{-1}$
<b>Coefficients cinétiques</b>	Notation	Valeur	Unité
Taux de croissance maximal de la biomasse hétérotrophe	4	$\hat{\mu}_H$	$j^{-1}$
Taux de croissance maximal de la biomasse autotrophe	0.5	$\hat{\mu}_A$	$j^{-1}$
Coefficient de mortalité de la biomasse hétérotrophe	0.3	$b_H$	$j^{-1}$
Coefficient de mortalité de la biomasse autotrophe	0.05	$b_A$	$j^{-1}$
Coefficient de demi-saturation en substrat rapidement biodégradable	10	$K_S$	$mgO_2.l^{-1}$
Coefficient de demi-saturation de l'oxygène pour la biomasse hétérotrophe	0.2	$K_{OH}$	$mgO_2.l^{-1}$
Coefficient de demi-saturation du nitrate pour la biomasse hétérotrophe	0.5	$K_{NO}$	$mgNO_3 - N.l^{-1}$
Coefficient de demi-saturation de l'azote ammoniacal pour la biomasse autotrophe	1.0	$K_{NH}$	$mgNH_3 - N.l^{-1}$
Coefficient de demi-saturation de l'oxygène pour la biomasse autotrophe	0.4	$K_{OA}$	$mgO_2.l^{-1}$
Coefficient de demi-saturation pour l'hydrolyse du substrat lentement biodégradable	0.1	$K_X$	$go_2 - X_S.(go_2 - X_{bh})^{-1}$
Facteur de correction pour $\hat{\mu}_H$ sous condition anoxie	0.8	$\eta_g$	-
Facteur de correction pour l'hydrolyse sous condition anoxie	0.8	$\eta_h$	-
Taux maximal pour l'hydrolyse	3	$K_h$	$go_2 - X_S.(go_2 - X_{bh}.j)^{-1}$
Taux d'ammonification	0.05	$K_a$	$m^3.(go_2.j)^{-1}$

Après avoir présenté les concepts de base du Benchmark BSM1, la simulation du Benchmark est indispensable, la figure 1.3 représente le simulateur en MATLAB/Simulink.

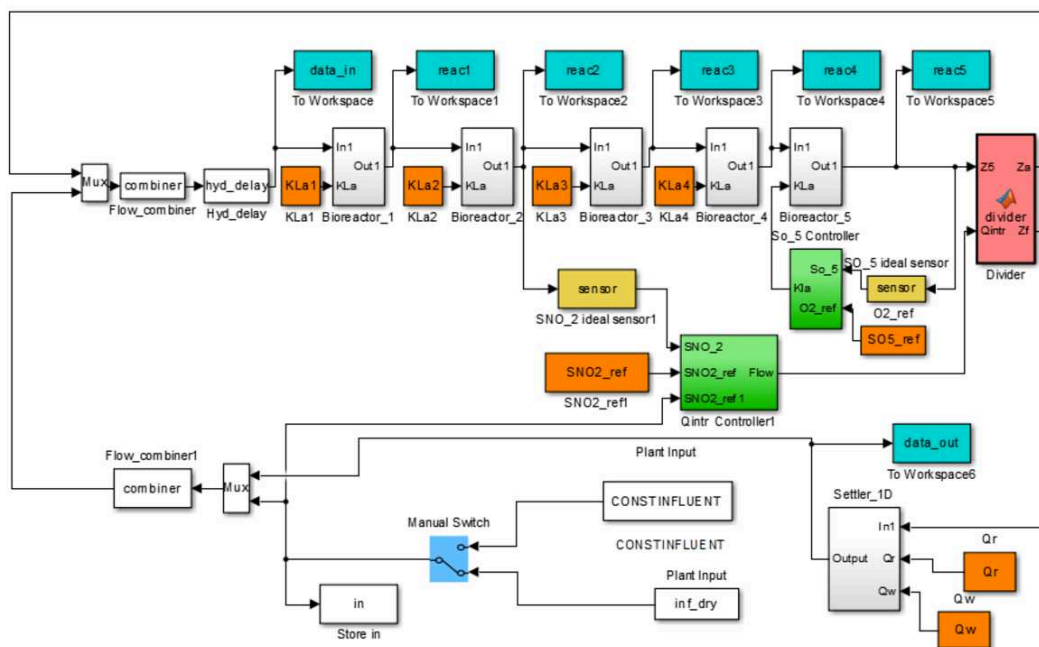


FIGURE 1.3 – Diagramme de simulation du BSM1.

### 1.3 Cas d'étude

Dans le but de rapprocher à la réalité et de tester la stratégie du surveillance et du diagnostic sur des données réelles collectées de la station d'Annaba, située dans le Nord-Est de l'Algérie (590 Km d'Alger et 8 Km en Est de la ville d'Annaba). L'ensemble des données est composé de 1344 observations de certains capteurs (voire le tableau 5.2) sous des conditions de fonctionnement normal, avec un débit moyen de  $18446 \text{ m}^3/\text{jour}$  et un pick de  $5923 \text{ m}^3/\text{h}$  pendant un temps sec.

Le procédé de purification utilisé est à la base de la boue activée et comporte deux secteurs principaux de traitement : Le primaire comprend des racks de barres, une chambre de grille, des filtres de l'huile et des filtres de sable, dont l'objectif est l'élimination des solides. Le secteur secondaire est conçu pour éliminer la matière organique présente dans les eaux usées influentes, où les polluants de la matière organique servent comme nourriture aux microorganismes. Cela se fait en utilisant des procédés de traitement aérobie ou anaérobie. Le schéma de l'usine actuelle utilisée est illustré dans la figure 1.4.

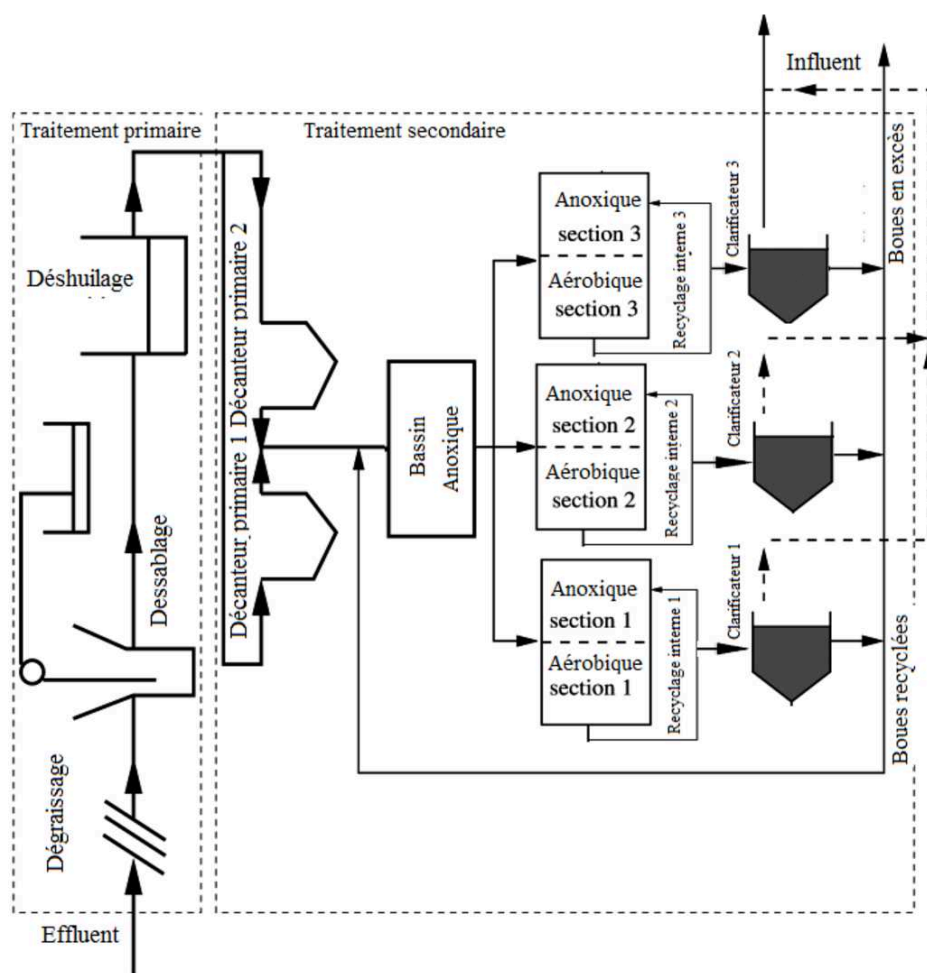


FIGURE 1.4 – Schéma de la station d'épuration des eaux usées d'Annaba.

#### 1.4 Conclusion :

Ce chapitre a été consacré à une représentation générale des concepts fondamentaux d'épuration biologique des eaux usées, où nous avons abordé dans un premier temps les différentes étapes de traitement biologique des eaux usées. Cependant, nous avons exposé en l'occurrence le Benchmark BSM1 ainsi une station d'épuration réelle, dont le but de valider l'ensemble des informations délivrées par les capteurs utiles à la commande des stations de traitement des eaux usées. Pour cela, nous avons eu recours à une matrice, dans un premier temps, constituée de données artificielles du Benchmark BSM1, puis de données réelles de l'ensemble des mesures disponibles (collectées lors du fonctionnement normal de la station de traitement des eaux usées réelle d'Annaba) dans la station. Ces données vont se servir pour construire le modèle et de faire des tests de simulation de la nouvelle stratégie de diagnostic des défauts capteurs.

## CHAPITRE 2

### ETAT DE L'ART SUR LE DIAGNOSTIC

#### 2.1 Introduction

Dès l'apparition de l'automatique moderne basée sur le calcul numérique, les méthodes de diagnostic fondées sur la redondance matérielle ou analytique ont connus un progrès à pas de géant en raison de leurs caractères à risque, comme les processus en génie des procédés, tel que environnementales dans le cas des procédés biologiques dépurations des eaux usées ainsi les processus chimiques, nucléaires,..., etc.

On dit qu'il y a un défaut dans un système dynamique lorsque la différence entre le comportement du système et son état de référence est importante, c'est le principe de base du diagnostic des défauts qui repose sur la notion de redondances que ce soit matérielle ou analytique. En effet, le diagnostic est devenu une nécessité urgente pour assurer la sûreté de fonctionnement des systèmes dynamique d'une part, et pour améliorer leurs performances en garantissant une meilleure fiabilité d'autre part.

Une procédure de diagnostic doit donc apporter des réponses aux questions suivantes en ce qui concerne ses objectifs, ses principes de mise en oeuvre et ses critères d'évaluation :

- *Objectifs* : Que veut-on contrôler ? Quels types de défauts doit-on détecter ?
- *Principes* : Quel est le principe de diagnostic à mettre en oeuvre ? Quelle est la procédure à suivre ?
- *Critères* : Quelles sont les performances souhaitées ? Quels sont les indices d'évaluation de ces performances ?

Cependant, la conception d'une procédure de diagnostic doit prendre en compte des aspects tels que le comportement du système et la sensibilité aux erreurs de mesure ainsi que les contraintes d'ordre économique et de mise en oeuvre pratique. Par conséquent et vue l'importance du problème de diagnostic et des difficultés rencontrées, plusieurs approches ont été développées au cours de ces dernières années. Elles couvrent une large variété de techniques telles que les approches à base de modèles. Ces approches exigent un modèle structurel du comportement du processus basé sur des principes physiques fondamentaux. Ces modèles peuvent être de type quantitatifs, exprimés sous forme d'équations mathématiques ou bien de type qualitatifs, exprimés par exemple sous forme de relations logiques.

D'autre part, il existe des méthodes qui ne nécessitent pas une forme explicite de modèle. Celles-ci ne dépendent que de l'historique de l'information. En addition avec la connaissance du système, il y a diverses techniques de diagnostic qui peuvent être appliquées sur ce système. Un tel assortiment de méthodes complique la tâche de diagnostic et rend le choix difficile pour toute personne qui n'est pas un expert dans ce domaine.

Ce chapitre est consacré à une synthèse bibliographique du diagnostic de défauts, inclut des généralités, définitions, terminologies et concepts suggérés par le comité technique SAFEPROCESS de l'IFAC (International Federation of Automatic Control), par le temps certaines définitions sont modifiées selon la terminologie présentée par [29].

## **2.2 Définitions et concepts**

Afin de développer notre propos, nous présentons quelques terminologies et concepts de base dans le domaine du diagnostic. La plus part de ces définitions ont été discutées au sein du SAFEPROCESS Technical Committee of International Federation of Automatic Control IFAC [30]. Fonctionnement normal : un système

est en fonctionnement normal lorsque ses états, ses entrées et ses sorties sont très proches de leur valeur nominale. Typiquement, il y a fonctionnement normal lorsqu'il n'y a pas d'apparition de défauts. Défaut : un défaut est généralement défini comme une déviation d'une variable observée ou d'un paramètre calculé par rapport à sa valeur fixée dans les caractéristiques attendues du processus lui-même, des capteurs, des actionneurs ou de tout autre équipement. Défaillance : une défaillance correspond à un défaut ayant un effet néfaste sur le fonctionnement du système. Ce terme est utilisé lorsqu'un dispositif devient inopérant ou il accomplit difficilement sa fonction. Détérioration : ce terme est utilisé pour définir une perte de performance altérant partiellement le fonctionnement du système. Panne : une panne est une interruption permanente de la capacité du système à réaliser sa fonction requise. Elle est au-delà de la défaillance car elle implique l'arrêt total du système. Erreur : elle est définie comme l'écart entre une valeur mesurée ou estimée d'une variable et une valeur donnée par un modèle et qui est théoriquement correcte. Résidu ou indicateur de défaut : il exprime l'incohérence entre les informations disponibles et les informations théoriques fournies par un modèle. Modélisation du défaut : c'est la détermination d'un modèle mathématique pour décrire un effet spécifique du défaut. Modèle qualitatif : c'est un modèle de système qui décrit le comportement avec des relations entre des variables et des paramètres du système en termes heuristiques tels que des causalités ou des règles. Modèle quantitatif : c'est un modèle de système qui décrit le comportement avec des relations entre des variables et des paramètres du système en termes analytiques tels que des équations différentielles ou aux différences. Seuil : c'est la valeur limite de l'écart d'un résidu avec le zéro, ainsi s'il est dépassé, un défaut est déclaré comme détecté. Détection de défaut : c'est la détermination de la présence de défaut et de l'instant de son occurrence. Isolation de défaut : c'est la détermination du type et de la localisation de défaut. Identification de défaut : c'est la détermination de la taille et du comportement temporel d'un défaut. Diagnostic : c'est la détermination du



type, de la taille, de la localisation et de l'instant d'occurrence d'un défaut, il suit la détection de défauts et inclut l'isolation et l'identification. Surveillance : c'est une tâche continue, réalisée en temps réel, de détermination de l'état d'un système physique qui consiste en l'enregistrement des informations ainsi la reconnaissance et l'indication des anomalies du comportement. Supervision : c'est la surveillance d'un système physique et la prise de décisions appropriées en vue de maintenir son opération lors de l'apparition de défauts. Dans le cadre de cette thèse, nous allons traiter exclusivement les défauts provenant des actionneurs. Dans une première phase d'étude, nous nous sommes intéressés aux défauts singuliers et par la suite aux défauts multiples. Pour cela, nous allons étudier les différentes approches de détection, d'isolation et d'identification des défauts.

### **2.3 Procédure de détection et d'isolation de défauts**

La détection et l'isolation de défauts est une opération délicate puisque il faut, dans un contexte soumis aux circonstances imprévisibles de fonctionnement du système et aux perturbations de l'environnement, décider s'il y a un défaut ou non. En effet, la détectabilité est défini comme étant l'aptitude du système de diagnostic à pouvoir découvrir la présence de défaut sur un système dynamique. Elle est fortement liée à la notion d'indicateurs de défauts qui s'appellent résidus générés par un générateur de résidu qui doit, d'une certaine manière, être sensible à la défaillance que l'on désire détecter. Généralement, Il faudra se fixer un compromis entre le nombre de fausses alarmes et celui de non-détection.

Concernant l'isolabilité, on peut dire qu'elle est la capacité du système de diagnostic à trouver l'origine du défaut. En général, une défaillance produit une cascade d'alarmes ce qui rend difficile l'isolation de l'organe défaillant. La capacité d'isoler les défauts est liée à la structure des résidus calculés et à la procédure de détection mise en oeuvre.

Ainsi le problème de détection et d'isolation de défauts consiste à mesurer les données au cours du fonctionnement réel du système et à générer les résidus afin de déterminer si le fonctionnement du système est normal ou défaillant après une comparaison avec son état de référence.

### 2.3.1 Différentes structures de défauts

Généralement, un défaut est caractérisé par une déviation de fonctionnement normal d'un système qui est circonvenue soit par les signaux de commande ou les signaux de mesures. Les défauts affectant un système sont d'évolutions, de natures et de types différents.

#### 2.3.1.1 Évolution des défauts

Les défauts peuvent être différenciés selon leur forme et leur comportement dans le temps [31]. En effet, ils peuvent surgir ou déjà être présent sur le système ; ils peuvent être de faible ou de forte amplitude, être brusque ou plutôt arriver graduellement sous forme de dérives lentes. Puisque l'apparence qui les définit est connue, ils sont dits déterministes. Par contre, les défauts se manifestant par intermittence sont dits stochastiques car ils ne peuvent être caractérisés que par des évolutions aléatoires.

Généralement on distingue dans la littérature trois types de défauts : - Défaut brusque ou abrupt (a) : il est caractérisé par son comportement temporel discontinu, il correspond à une panne brutale : disfonctionnement total ou partiel. Une représentation mathématique de ce défaut est donnée par :

$$f(t - t_f) = \begin{cases} \delta & t > t_f \\ 0 & t < t_f \end{cases} \quad (2.1)$$

où,  $t_f$  représente le temps d'occurrence d'un défaut,  $f(t - t_f)$  est le comportement

temporel du défaut et  $\delta$  est un seuil constant.

- Défaut intermittent (b) : ce défaut est un cas particulier de défaut abrupt avec la propriété particulière que le signal revient de façon aléatoire à sa valeur nominale. Ce type de défaut caractérise les faux contacts ou une panne intermittente des capteurs.

- Défaut à dérive lente ou graduel (c) : ce défaut a un comportement temporel lent ce qui le rend difficile à détecter, il est caractéristique d'un encrassement ou d'une usure d'une pièce. Son évolution au cours du temps peut être exprimée par cette relation :

$$f(t - t_f) = \begin{cases} \delta(1 - e^{-\alpha(t-t_f)}) & t \geq t_f \\ 0 & t < t_f \end{cases} \quad (2.2)$$

où  $\alpha$  et  $\delta$  sont deux constantes positives.

### 2.3.1.2 Nature des défauts

Les défauts peuvent être classés en défauts de nature multiplicative ou de nature additive (figure 2.1), selon leurs effets sur les performances du système.




FIGURE 2.1 – Modélisation des défauts.

- **Défauts multiplicatifs (a)** : les défauts au niveau de la dynamique du procédé sont modélisés par des défauts multiplicatifs. Ils correspondent aux modifications paramétriques du modèle représentant le système. Ces derniers induisent

des changements sur la corrélation du signal de sortie du système, ainsi que des changements dans la dynamique du système.

- **Défauts additifs (b)** : ces défauts sont modélisés sous forme de termes additifs dans le modèle du système. Ils influent sur son état ou sur sa sortie. Cette modélisation est habituellement attribuée aux défauts d'actionneurs et de capteurs.

### 2.3.1.3 Types de défauts

Comme il est connu, couramment pour la procédure de diagnostic, on utilise la modélisation pour caractériser le système à surveiller et on cherche toujours à définir un modèle représentant d'avantage son fonctionnement. Toutefois, on doit prendre en compte la modélisation des défauts quand le système est affecté par un défaut. Et par la suite, on a besoin de différencier ces défauts selon leurs natures. En effet, ils peuvent affecter le procédé, les actionneurs ou bien les capteurs. Donc, trois types de défauts peuvent toucher les différents éléments d'un système :

- **Défauts capteurs** : les capteurs servent à transformer une grandeur physique en une grandeur capable d'être traitée par les calculateurs. Ils sont généralement les interfaces de sortie d'un système avec l'environnement extérieur. Ainsi, les défauts provenant des capteurs se caractérisent par un écart entre la valeur réelle de la grandeur et sa mesure. Ils s'additionneront aux sorties du système et représenteront l'ensemble des problèmes liés à la prise d'information sur l'état du système. Comme pour le défaut actionneur, le défaut provenant du capteur peut être total ou partiel. Un défaut partiel issu d'un capteur peut être représenté par une saturation, un défaut au niveau de calibrage, un biais ou un bruit. D'ailleurs, la relation entre le signal généré par le capteur et celui du système réel est toujours plus ou moins adéquate. Par contre, dans le cas d'un défaut total, l'exploitation du signal du capteur n'est pas possible.

- **Défauts actionneurs** : les actionneurs sont considérés comme la partie opérative qui agit sur le système et transforme les signaux de commande issus du

contrôleur en mouvement d'un moteur ou en chaleur délivrée par une résistante électrique ou bien en champ magnétique à partir d'un électroaimant etc... Ainsi les défauts actionneurs s'additionneront aux commandes du système et concerneront l'ensemble des problèmes liés aux organes qui agissent sur l'état du procédé. Ils se traduisent donc par une incohérence entre la commande des actionneurs et la réponse en leur sortie. L'actionneur peut être en perte totale ou en perte partielle.

Pour le premier cas, cet actionneur est devenu incapable de commander le système comme par exemple une vanne qui reste bloquée dans sa position initiale. Dans le deuxième cas, l'actionneur est caractérisé par un fonctionnement dégénéré, c'est-à-dire, il fonctionne comme étant en régime nominal mais son action est à peine partielle. Ce phénomène est souvent caractérisé par une perte d'énergie.

- **Défauts procédé** : ce sont les défauts affectant le système lui-même, ils correspondent à une dégradation des composants du système par un changement sur les paramètres internes. Ces défaillances sont dues alors à des modifications de la structure ou des paramètres du modèle.

Dans cette thèse, nous nous sommes intéressés aux défauts capteurs. Bénéficiant des outils déjà existants en Automatique, la recherche dans ce domaine a connu une évolution très importante qui lui a permis de développer plusieurs méthodes donnant une solution aux problèmes de la détection et de l'isolation de défauts. [32]

## 2.4 Classification des méthodes de diagnostic

Dans les dernières années plusieurs méthodes de diagnostic des défauts ont été utilisées dans l'industrie. Dans ce contexte, nous présentons les principales méthodes de diagnostic rencontrées dans la littérature. Leur principe général repose sur une comparaison entre les données observées au cours du fonctionnement du système et les connaissances acquises sur son comportement normal et ses comportements de défaillance [33].

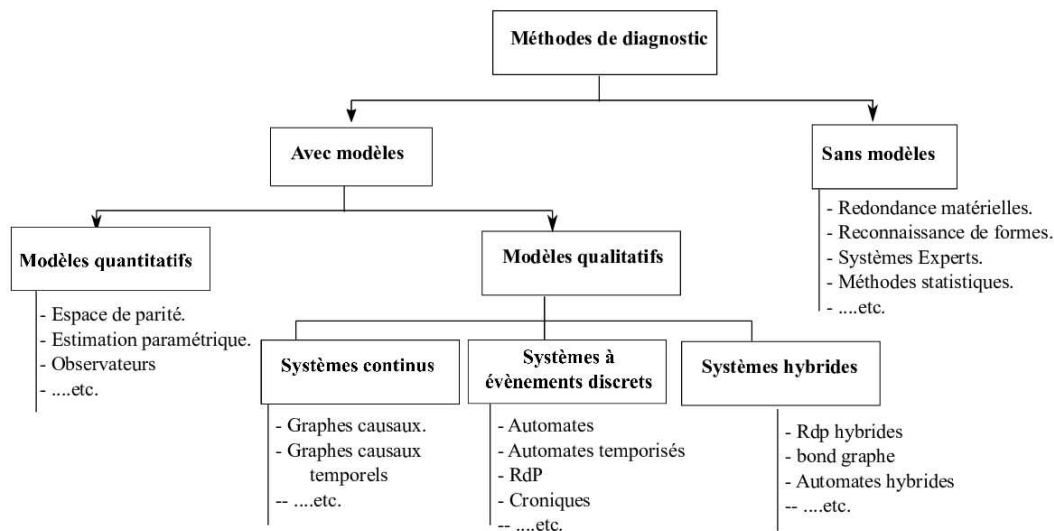


FIGURE 2.2 – Classification des méthodes de diagnostic.

Ces méthodes se distinguent selon différents critères tels que la nature de l'information disponible (quantitative ou qualitative), sa profondeur (structurelle, fonctionnelle et/ou temporelle), sa complexité, l'implémentation de diagnostic en ligne et/ou hors ligne, la dynamique du système (continu, discret ou hybride), la structure de prise de décision (centralisée, décentralisée ou distribuée)...

La figure 2.2 présente une classification des méthodes de diagnostic non exhaustive des méthodes de diagnostic selon deux grandes familles :

- Les méthodes sans modèle mathématique qui ne nécessitent pas de connaissances accrues du système physique, mais utilisent des connaissances superficielles,
- Les méthodes à base de modèles qui nécessitent une connaissance approfondie du système physique.

Ces classifications sont influencées par les terminologies et les contextes particuliers de chaque communauté et ne sont pas toujours homogènes. Nous référons aux lecteurs les travaux suivants pour avoir plus de détails : [33–39].

### 2.4.1 Méthodes avec modèles

Les approches à base de modèles s'appuient sur des modèles comportementaux explicites du système soumis au diagnostic. Un grand avantage de ces approches par rapport aux approches relationnelles et de traitement de données, réside sur le fait que seule l'information du comportement normal du procédé est prise en compte par l'intermédiaire d'un modèle de référence. La précision du modèle, liée aux besoins de la surveillance et aux critères de performance du diagnostic, définit le choix de l'utilisation de modèles quantitatifs ou qualitatifs. Selon [40] les méthodes de diagnostic à base de modèles présentent aussi les avantages suivants :

- La connaissance sur le système est découplée de la connaissance de diagnostic,
- Il s'agit d'une connaissance de conception plutôt que d'exploitation,
- Le coût de développement et de maintenance est moindre,
- Les modèles fournissent un support adéquat pour l'explication (la structure du système est explicitement représentée).

De nombreux travaux font régulièrement le point sur l'avancement de différentes approches que nous pouvons classer selon deux branches principales : les approches qualitatives et les approches quantitatives.

### 2.4.2 Méthodes sans modèles

Dans certains cas, il s'avère difficile ou parfois impossible de trouver le bon modèle mathématique pour un système réel, à cause des nombreuses reconfigurations intervenant dans le processus de production ou de la complexité des phénomènes mis en jeu. La solution dans ce cas est le recours à des méthodes qui ne nécessitent aucune connaissance approfondie du système.

En effet, on trouve :

- Les approches quantitatives qui sont basées sur le traitement de données.

- Les approches qualitatives à base de connaissance.

## **2.5 Conclusion :**

Nous avons présenté dans ce chapitre un état de l'art sur le diagnostic de défauts dans les systèmes dynamiques dont l'intérêt se portera essentiellement sur le problème de détection, d'isolation et d'identification de défauts. Au préalable, il était nécessaire de donner les différents concepts, notions et outils du diagnostic de défauts généralement cités et utilisés dans la littérature, puisque un bon diagnostic demande une bonne compréhension de ces notions. En effet, dans ce chapitre nous avons rappelé les définitions fondamentales des techniques les plus connues et les plus couramment utilisées dans le domaine du diagnostic de fonctionnements des systèmes industriels.

Nous nous intéresserons dans notre travail aux approches de diagnostic sans modèle, en particulier les méthodes d'analyse des données statistiques sous la forme de données historiques qui correspondent aux différents modes de fonctionnement du système ou bien à l'aide d'un traitement en ligne des signaux issus de capteurs, en supposant que les signaux fournis les capteurs possèdent certaines propriétés statistiques, sur lesquelles des tests de seuil sont établis.



## CHAPITRE 3

### DIAGNOSTIC À BASE D'ANALYSE DE DONNÉES STATISTIQUES MULTIVARIÉS

#### 3.1 Introduction

Aujourd'hui, nombreuses approches d'analyse des données statistiques multivariées ont été développées pour contribuer au diagnostic de défauts. Tandis que, il s'avère nécessaire de fournir une stratégie de surveillance et diagnostic des systèmes, en apportant les moyens de détection et d'isolation des défauts appropriés afin de garantir le bon fonctionnement, vis-à-vis des objectifs qui lui ont été assignés.

L'Analyse en Composantes Principales (ACP) a été largement utilisée comme un outil de modélisation (modèle) des processus linéaires. Cependant, leurs extensions tel que : l'ACP multi-échelles et l'ACP non linéaire (à base de réseaux de neurones artificiels sous forme de mémoires auto-associatives) ont été utilisées dans le cas des systèmes à caractéristiques non linéaires. Le modèle obtenu permet d'estimer les variables du processus à surveiller.

Dans ce chapitre, nous allons présenter quelques notions de base liées à l'approche de l'analyse en composantes principales pour bien comprendre leurs extensions non linéaires : l'ACP multi-échelles et l'ACPNL à base de réseaux de neurones artificiels.

#### 3.2 L'analyse en composantes principales

L'Analyse en Composantes Principales (ACP) est une méthode de la famille de l'analyse des données et plus généralement de la statistique multi-variée, qui consiste à transformer des variables liées entre elles (dites "corrélées" en statistique) en nouvelles variables décorrélatées les unes des autres. Ces nouvelles variables sont

nommées "composantes principales", ou axes. Elle permet au praticien de réduire l'information en un nombre de composantes plus limité que le nombre initial de variables. Il s'agit d'une approche à la fois géométrique (représentation des variables dans un nouvel espace géométrique selon des directions d'inertie maximale) et statistique (recherche d'axes indépendants expliquant au mieux la variabilité - la variance - des données). Lorsqu'on veut alors compresser un ensemble de variables aléatoires, les premiers axes de l'ACP sont un meilleur choix, du point de vue de l'inertie ou la variance expliquée.

L'ACP consiste à remplacer un nombre de variables par des nouvelles variables de *dimension inférieure, variance maximale, et non corrélées deux à deux*. Ces nouvelles variables appelées *composantes principales* "CPS". Ces axes principaux sont les axes de direction des vecteurs propres de la matrice de covariance des variables du processus où le premier axe est celui associé à la plus grande valeur propre et le deuxième axe, orthogonal au premier, est associé à la deuxième plus grande valeur propre..., et alors le dernier axe, est celui associé à la plus faible valeur propre. Les deux ou les trois premiers axes principaux constituent les directions de l'*espace réduit* "EP" qui appartient à l'espace original de données. Cette approche basée sur la projection de l'ensemble originale de données sur ce nouvel espace de dimension inférieur, en suite, et à partir de la matrice de projection, on peut estimer nos informations originales en minimisant l'erreur d'estimation, dans ce sens l'ACP peut considérer comme une technique de minimisation de l'erreur d'estimation, autrement dit, les données estimées doivent être approximativement proches des valeurs originales.

### 3.3 Identification du modèle ACP

Supposons  $X$ , une matrice de  $n$  observations  $x_{ij}$  où le nombre de colonnes correspond au nombre de dimensions des données. Au préalable, Afin de rendre le résultat indépendant des unités utilisées pour chaque variable, un pré-traitement indispensable consiste à centrer et réduire les variables. Pour cela nous supposons, que l'on soustrait à chaque colonne de l'ensemble de départ la moyenne  $\mu_j$  (moyenne de la dimension correspondante) et on divise sur l'écart type  $\sigma_j$  (moyenne de la dimension correspondante). On obtient alors une nouvelle matrice normalisée  $Y$  ayant sa moyenne centrée en zéro. Le calcul de l'ACP est défini de telle sorte que chaque colonne  $Y_j$  de la nouvelle matrice centrée réduite est donnée par :

$$Y_j = \frac{Y_j - M_j}{\sigma_j} \quad (3.1)$$

Une fois que les données ont été centrées réduites, la matrice de corrélation de données,  $\Sigma$ , peut être calculée comme suit :

$$\Sigma = \frac{Y^T Y}{N - 1} \quad (3.2)$$

Calculer  $Y^T Y$  revient à produire une matrice contenant les sommes des déviations. Multiplier  $Y^T Y$  par  $1/(n - 1)$  permet d'obtenir la matrice  $\Sigma$  où les éléments situés sur la diagonale correspondent à la variance  $\sigma_{ij}^2$  et les autres éléments à la co-variance  $\sigma_i \sigma_j$ .  $\Sigma$  est souvent appelée la matrice de covariance de  $X$ .

Les valeurs propres de la matrice de covariance  $\Sigma$  représentent les variances des projections  $t$  des données sur les directions représentées par les vecteurs propres  $p_i (i = 1, 2, \dots, m)$ . En conclusion, la direction suivant laquelle la variance de la projection du vecteur de données  $x$  est maximale, est représentée par le vecteur propre  $p_i$  correspondant à la valeur propre maximale.

Le sous-espace vectoriel de dimension  $\ell$  qui assure une dispersion maximale des

observations est défini par une base orthonormée formée des  $\ell$  vecteurs propres correspondant aux  $\ell$  plus grandes valeurs propres de la matrice  $\Sigma$ . Il est donc possible de réduire la dimension de la représentation des données en ne retenant de l'expression précédente que les termes  $t_j p_j (j = 1, \dots, \ell)$  associés aux  $\ell$  plus grandes valeurs propres. L'ACP donc détermine une transformation optimale (vis à vis d'un critère de variance) de la matrice de données  $X$  :

$$T = XP \quad (3.3)$$

$$X = TP^T \quad (3.4)$$

Où  $T \in R^{n \times m}$  et  $P \in R^{m \times m}$  Sont les matrices des composantes principales et des vecteurs propres correspondants issus de la décomposition spectrale de la matrice de covariance  $\Sigma$  de  $Y$ . Les relations 3.3 3.4 trouvent leur intérêt lorsqu'on diminue la dimension de l'espace de représentation. Une fois déterminé le nombre  $\ell < m$  de composantes à retenir, la matrice  $X$  des données peut être approximée. Pour cela la matrice des vecteurs propres est partitionnée sous la forme :

$$P = (\hat{P} \tilde{P}) \quad \text{avec } P \in R^{n \times l} \quad (3.5)$$

Les  $\ell$  premiers vecteurs propres  $\hat{P}$  constituent l'espace principal alors que les  $(m - \ell)$  derniers vecteurs propres  $\tilde{P}$  constituent l'espace résiduel. A partir des équation 3.3 et 3.4, on peut alors expliciter la partie  $\hat{X}$  des données expliquées par les  $\ell$  premiers vecteurs propres et la partie résiduelle  $\tilde{X}$  expliquée par les composantes restantes :

$$\hat{X} = X \hat{C}^\ell \quad \text{Où } \hat{C}^\ell = \hat{P} \tilde{P}^T \quad (3.6)$$

$$E = X - \hat{X} = X(I - \hat{C}^\ell) \quad (3.7)$$

L'identification du modèle ACP consiste donc à estimer ses paramètres par une décomposition en valeurs et vecteurs propres de la matrice  $\Sigma$  et à déterminer le nombre  $\ell$  de composantes principales à retenir.

### 3.4 Choix de la dimension de l'espace réduit et de nombre des CPs

Plusieurs méthodes pour la détermination du nombre optimal des composantes principale à retenir ont été proposés pour construire un model ACP, ce qui prouve que cette dernière peut être considérée comme une approche de modélisation avec laquelle on peut obtenir un modèle adéquat au système, c'est l'étape primordiale de la modélisation à base de l'ACP. Si peu de composantes principales sont sélectionnées par rapport à celles exigées, le modèle sera inadéquat et la représentation des résultats sera incomplète. Par contre, si plus de CPs sont retenues, le modèle sera sur-paramétré et peut éventuellement contenir des bruits de mesures. Pour cela, nous utilisons et comparons trois approches, pourcentage cumulé de la variance totale, moyenne des valeurs propres et le critère de validation croisée disponibles dans la littérature [41, 42]

#### 3.4.1 Pourcentage cumulé de la variance (PCV) :

Le principe de cette technique de sélection basé sur l'estimation du pourcentage de la variance de composantes principales. Pour choisir la dimension réduite, il faut choisir le pourcentage de la variance totale qu'on veut conserver.

Généralement :

$$PCV(\ell) = 100 \left( \frac{\sum_{j=1}^{\ell} \lambda_j}{\sum_{j=1}^m \lambda_j} \right) \% \quad (3.8)$$

### 3.4.2 Variance de l'erreur de reconstruction (VER) :

Cette technique basée sur la reconstruction des variables à partir du modèle et des autres variables de la matrice de données. Le principe est de chercher le nombre de composantes principales qui permet de minimiser la variance de l'erreur de reconstruction ou la variance non reconstruite et alors qui permet d'optimiser la reconstruction des variables.

Le modèle du comportement par "ACP" est  $\hat{C}$  où :

$$\hat{X} = X\hat{C} \quad \text{et} \quad \tilde{X} = X\tilde{C} \quad (3.9)$$

Supposons que  $C_j^T = \begin{bmatrix} C_{-j}^T & C_{jj}^T & C_{+j}^T \end{bmatrix}$  est le  $j^{\text{ème}}$  colonne de  $\hat{C}$

Et  $v_j$  est la variable à reconstruire, où la reconstruction de  $v_j$  notée  $z_j$  :

$$z_j = \frac{1}{1 - C_{jj}^T} \begin{bmatrix} C_{-j}^T & 0 & C_{+j}^T \end{bmatrix} x(k) \quad (3.10)$$

$C_{-j}^T$  : les  $(j - 1)$  premiers éléments de la  $j^{\text{ème}}$  colonne de  $\hat{C}$

$C_{+j}^T$  : les  $(m - j)$  derniers éléments de la  $j^{\text{ème}}$  colonne de  $\hat{C}$

$x(k)$  le vecteur contenant  $m$  variables observées du système à l'instant  $k$  :

$$x(k) = \begin{bmatrix} x_1(k) & x_2(k) & \cdots & x_m(k) \end{bmatrix}^T$$

Et alors le vecteur de mesure  $x(k)$  avec la reconstruction de la  $j^{\text{ème}}$  variable est le suivant :

$$x(k) = \left[ x_1(k) \quad \cdots \quad x_{j-1}(k) \quad z_j(k) \quad x_{j+1}(k) \quad \cdots \quad x_m(k) \right]^T$$

Dans cette méthode, le but est de minimiser la variance de l'erreur de reconstruction de la  $j^{\text{ème}}$  variable de  $x(k)$  :

$$\varepsilon = \xi_j^T [x(k) - x_j(k)] \quad (3.11)$$

$$\text{Où } \xi_j^T = \left[ 0 \quad \cdots \quad 1 \quad \cdots \quad 0 \right]^T$$

Le nombre de composantes principales à retenir s'obtient en minimisant par rapport à  $\ell$  le critère suivant :

$$VER(\ell) = \sum_{j=1}^m \frac{\sigma_j(\ell)}{\xi_j^T \sum \xi_j} \quad (3.12)$$

avec  $\ell = 1, \dots, m - 1$

### 3.4.3 Détection et localisation traditionnelles de défauts par ACP

#### 3.4.3.1 L'indice de détection SPE

Classiquement, plusieurs indicateurs de détection sont utilisés pour la détection d'un fonctionnement anormal par ACP. La plus part des études récentes utilisent L'indicateur typique le plus populaire : *l'erreur quadratique de prédiction ( Squared Prediction Error SPE )* pour la détection les conditions de fonctionnement anormales des processus. Cet indicateur réalise la détection des défauts dans l'espace résiduel et donne l'ordre sur l'apparition ou non d'un défaut. A l'instant  $K$ , il est donnée par l'équation suivante :

$$SPE(k) = e(k)e(k)^T \quad (3.13)$$

où ;

$$e(k) = x(k) - \hat{x}(k) \quad (3.14)$$

$\hat{x}(k)$  est l'estimation de la matrice  $x$  des variables à surveiller.

Le processus est considéré en fonctionnement anormal (présence d'un défaut) à l'instant  $k$  si :

$$SPE(k) \geq \delta_\alpha^2 \quad (3.15)$$

Où  $\delta_\alpha^2$  est le seuil de confiance. Box [6] a montré que :

$$\delta_\alpha^2 = g\chi_{h,\alpha}^2 \quad (3.16)$$

Où :

$$g = \frac{\theta_2}{\theta_1} \quad (3.17)$$

$$h = \frac{\theta_1^2}{\theta_2} \quad (3.18)$$

$$\theta_i = \left( \sum_{j=\ell+1}^m \lambda_j^i \right)_{i=1,2,3} \quad (3.19)$$

$\delta_\alpha^2$  peut être approximée par  $\chi^2$  - *distribution*, avec  $h$  est le degré de liberté,  $\alpha$  est le niveau de confiance et  $g$  est un coefficient .



### 3.4.3.2 Filtre EWMA

Pour améliorer la qualité de la détection et réduire les fausses alarmes, un filtre EWMA (*Exponentially Weighted Moving Average*) peut être appliqué aux résidus, son expression générale est donnée par :

$$\bar{e}(k) = (I - \beta)\bar{e}(k - 1) + \beta e(k) \quad (3.20)$$

$$\overline{SPE}(k) = \|\bar{e}(k)\|^2 \quad (3.21)$$

Où  $\beta$  est une matrice diagonale dont les éléments sont les facteurs d'oubli pour les résidus,  $I$  est une matrice identité et  $\bar{e}(k) = 0$ .

Avec,  $\bar{e}(k)$   $\overline{SPE}(k)$  sont les vecteurs filtrés des résidus  $e(k)$  et de l'erreur quadratique carrée  $SPE$  respectivement. Il faut noter que le  $\overline{SPE}(k)$  permet de réduire les fausses alarmes mais il introduit un certain retard à la détection.

Pour simplifier, nous supposons dans la suite que la matrice des facteurs doublis est donnée par :

$$\beta = \gamma I \quad (3.22)$$

Dans ce cas, le processus est considéré en fonctionnement anormal (présence d'un défaut) à l'instant  $k$  si :

$\overline{SPE}(k) > \bar{\delta}_\alpha^2$  où  $\bar{\delta}_\alpha^2$  est le seuil de confiance filtré pour cet indicateur filtré qui est donné par la formule suivante :

$$\bar{\delta}^2 = \frac{\gamma}{2 - \gamma} \delta_\alpha^2 \quad (3.23)$$

Où  $\gamma$  est un facteur doublis.

### 3.5 Localisation par ACP

#### 3.5.1 Localisation de défauts par calcul des contributions

Une fois que le défaut est détecté il est nécessaire d'identifier la ou les variables qui sont en cause, c'est le principe de localisation de défauts. La méthode de contribution basée sur le calcul des taux de contribution de chaque variable à la valeur de l'indice de détection est l'approche la plus utilisée pour la localisation des défauts [7], la variable ayant la plus forte contribution est considérée comme la variable en défaut [43–49].

Cette approche est basée sur le calcul de détection  $SPE$ , où la contribution  $cont_{SPE}^j(k)$  de la  $j$ ème variable à l'instant  $k$  est définie par l'équation suivante [43, 44] :

$$Cont_j^{SPE}(k) = (e_j(k))^2 = (x_j(k) - \hat{x}_j(k))^2 \quad (3.24)$$

La variable ayant la plus forte contribution à l'instant de détection est la variable affectée.

$x_j(k)$  est le  $j$ ème élément du vecteur de mesures  $x$  à l'instant  $k$  donnée.

#### 3.5.2 Indice de validité des capteurs (SVI) :

Cette méthode se base sur le principe de reconstruction de toutes les variables à partir de l'instant de détection en calculant les indices de validité des capteurs. Par exemple si on détecte un défaut à l'instant de temps  $k$ ,  $SPE_j(k)$  représente l'indice de détection de la  $j$ ème variable reconstruite.

La localisation est effectuée par la comparaison de l'indice de détection avant et après la reconstruction. Cette comparaison est appelée indice de validité  $\eta_j(k)$  où :

$$\eta_j(k) = \frac{SPE_j(k)}{SPE(k)} \quad (3.25)$$

Cet indice est toujours inférieur ou égale à 1 ( $\eta \in [0 \ 1]$ ) parce que l'indice de détection  $SPE(k)$  est toujours supérieur ou égale à  $SPE_j(k)$ . Si le  $j$ ème capteur est défaillant, l'indice de validité de ce capteur doit être descendant vers le zéro.

Notons que l'équivalence filtrées de ce critère donné par :

$$\bar{\eta}_j^2(k) = \frac{\overline{SPE}_j(k)}{\overline{SPE}(k)} < 1 \quad (3.26)$$

$\Rightarrow$  la  $j$ ème variable est affectée par un défaut.

### 3.6 Extension non linéaire de l'ACP

L'analyse en composantes principales est la méthode de la statistique multivariée la plus utilisée dans les recherches de la surveillance des processus industriels. Malheureusement, comme c'est une opération de projection linéaire, seules les dépendances linéaires ou quasi-linéaires entre des variables peuvent être révélées. Si les données à traiter présentent des comportements non linéaires, l'ACP est incapable de trouver la représentation compacte décrivant ces données. Plusieurs extensions de l'analyse en composantes principales pour traiter les problèmes non linéaires ont été proposées dans la littérature [12, 14, 50, 51]. Dans cette thèse, nous intéressons exclusivement aux méthodes plus populaires dans la littérature qu'elle sont l'Analyse en composantes principale multi-échelle et l'ACP NL à base de réseaux de neurones artificiels.

### 3.6.1 Analyse en composantes principale multi-échelle

En 1998 Bakshi [14] a proposé une extension non linéaire de l'ACP basé sur un principe de décomposition multi-échelle, ce principe s'articule sur la surveillance du signal reconstruit après le filtrage de chaque coefficient d'ondelette. cette méthodologie qui repose sur la combinaison de l'ACP et les ondelettes permet de détecter en cas de présence d'un évènement anormal provenant d'un capteur dans le processus. La détection se fait en chaque échelle et en gardant juste les échelles significatives où la détection s'est produite en reconstruisant le signal original du capteur en défaut. La figure 3.1 représente la méthodologie ACP Multi-Echelle proposée par [14], avec une matrice des données brutes  $X$  et  $\hat{X}$  est la matrice des données reconstruites, alors que  $W$  et  $W^T$  représentent la transformée et la transformée inverse en ondelettes.




FIGURE 3.1 – Cycle de surveillance de processus.

#### 3.6.1.1 Ondelette et Analyse multi-résolution

En 1983 Jean Morlet [52] a inventé les fonctions d'ondelettes pour la première fois pour traiter les signaux sismiques. Dès lors, plusieurs travaux de recherches pour élaborer la théorie d'ondelettes [52–56] mais l'excellente introduction au sujet des ondelettes est présentée en 1995 par Hubbard [54].

Dans le domaine de la surveillance par l'analyse en composante principale Bakshi [14] et Kosanovich K.A. and Piovoso. M.J. [53] sont les premiers qui ont proposé la méthode l'ACP Multi-Echelle, qui consiste à construire des modèles ACP pour chaque échelle d'ondelette (niveaux de décomposition en ondelette), cette combinaison entre les variables et de l'analyse en ondelette consiste à décomposer chaque signal de capteur en signaux d'approximation et de détails à différentes échelles. L'avantage de cette décomposition est que la taille de la fenêtre d'analyse (ondelette mère) est variable et décalée dans le temps. Chaque dilatation ou compression de l'ondelette mère donne naissance à une échelle. Chacune des échelles est composée de coefficients, dites coefficients d'ondelettes, ils représentent le signal sur différentes échelles (décomposition multi-échelle) [57]. Une famille de fonction d'ondelettes sont ainsi créés avec la même forme que l'ondelette mère mais avec des tailles et des localisations différentes. La famille d'ondelette peut être définie comme suit :

$$\Psi_{s,u}(t) = \frac{1}{\sqrt{|s|}} \Psi\left(\frac{t-u}{s}\right) \quad (3.27)$$

avec  $s$  est le paramètre de dilatation qui détermine la localisation de l'ondelette dans le domaine temporel et  $u$  le paramètre de translation détermine la localisation de l'ondelette dans le domaine fréquentiel. Dans ce travail, nous nous intéressons par le transformée en ondelettes discrètes ( Discret Wavelet Transform DWT) en discrétisant les paramètres de dilatation  $s$  et de de translation  $u$ . Dans le cas discret ces paramètres sont donnés comme suit :

$$s = 2^j \quad u = 2^j k = sk; \quad k \in Z.$$

$$\Psi_{j,k}(t) = 2^{\frac{j}{2}} \Psi(2^j t - k) \quad (3.28)$$

Mallat [58] dans sa théorie de l'analyse multi-résolution a défini ces bases d'onde-

lettres orthogonales en utilisant un algorithme de la transformée en ondelettes rapide FWT (Fast Wavelet Transform) qui repose sur des bancs de filtres miroirs en quadratures. La théorie montre que n'importe quel signal  $f(t)$  peut être décomposé par une projection sur des fonctions échelons et fonctions ondelettes. L'algorithme récursif pour la décomposition en ondelette est aussi connu sous le nom d'algorithme pyramide ou bien transformée en ondelette rapide.

Alors donc , si nous supposons que  $\Phi_{j,k}(t)$  et  $\Psi_{j,k}(t)$  sont respectivement les versions d'ondelettes discrètes translatée et dilatée sont décrites comme suit :

$$\Phi_{j,k}(t) = 2^{\frac{-j}{2}} \Phi(2^{-j}t - k) \quad (3.29)$$

$$\Psi_{j,k}(t) = 2^{\frac{-j}{2}} \Psi(2^{-j}t - k) \quad (3.30)$$

- la projection sur des fonctions échelons se traduit par le produit du signal  $f(t)$  avec la fonction  $\Phi_{j,k}(t)$  est généralement connue par le coefficient d'approximation (ou d'échelon)  $a_{jk}$ , ces coefficients sont des versions lissées du signal original  $f(t)$ .
- Alors que la projection sur des fonctions ondelettes consiste à convoluer le signal original  $f(t)$  avec la fonction  $\Psi_{j,k}(t)$  qui est connue comme étant le coefficient d'ondelette  $d_{jk}$ , ces coefficients sont connues aussi sous le nom de détails du signal perdue en passant d'une échelle à une autre plus grande.

$$a_{j,k}(f, \Phi_{jk}) = \int f(t) \Phi_{jk}(t) dt \quad (3.31)$$

$$d_{j,k}(f, \Psi_{jk}) = \int f(t) \Psi_{jk}(t) dt \quad (3.32)$$

Ces équations peuvent être écrites sous la forme discrète suivante :

$$a(j) = \sum_{k=-\infty}^{\infty} x(k)g(2j - k) \quad (3.33)$$

$$d(j) = \sum_{k=-\infty}^{\infty} x(k)h(2j - k) \quad (3.34)$$

avec  $g$  est le coefficient de la fonction échelon qui est filtre passe bas, et  $h$  le coefficient de la fonction ondelette qui est un filtre passe haut. Il faut noter que les coefficients d'ondelette contiennent toujours l'information portée par le signal original.

Pour chaque filtre passe haut et passe bas, il existe leurs filtres de reconstruction correspondant. En utilisant ces filtres pour la reconstruction, avec le sur-échantillonnage correspondant et en sachant que les filtres sont biorthogonaux, ceci résultera en une reconstruction parfaite du signal original uni-échelle.

### 3.6.2 ACPNL par réseaux de neurones auto-associatifs

L'ACP non linéaire donc est une extension de l'ACP linéaire, dont l'objectif est d'extraire à la fois les relations linéaires et non linéaires. Cette généralisation est effectuée par une projection des données sur des courbes au lieu des droites, Hastie [50] propose une approche pour une généralisation de l'ACP dans le cas non linéaire basée sur le principe des courbes principales. Kramer [12] a proposé une extension non linéaire de l'analyse en composantes principales utilisant un réseau de neurones artificiels possède cinq couches dont les poids sont calculés par apprentissage en minimisant l'erreur quadratique entre les entrées et les sorties du réseau. Plusieurs auteurs ont utilisés les réseaux de neurones artificiels dont le but de traiter les problèmes non linéaires par l'approche de l'analyse en composantes principales [10, 51]. La plupart des travaux repose sur l'approche neuronale pour le calcul du modèle ACPNL qui a été proposée par Kramer [12].

La figure ci-dessous 3.2 représente une topologie d'un réseau de neurones artificiels sous forme de mémoires auto-associatives possédant cinq couches avec trois couches cachées : couche de compression, couche d'étranglement et couche de dé-compression (Bottleneck Neural Network BNN).

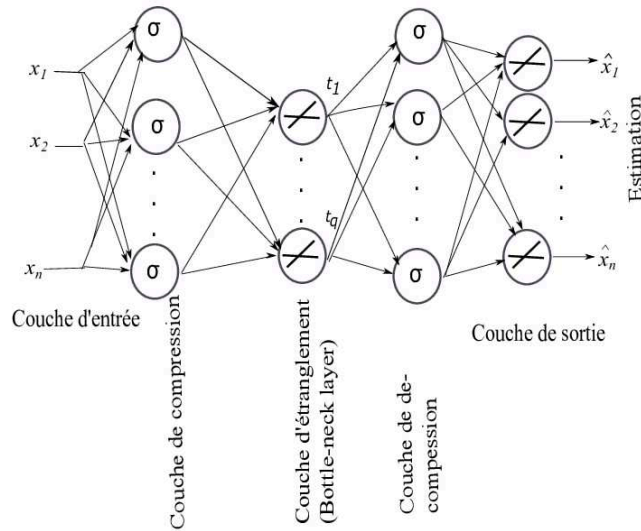


FIGURE 3.2 – ACPNL par réseaux de neurones Auto-associatifs.

L'apprentissage du réseau BNN contient deux étapes : Etape de compression (Codage) : pour un vecteur d'entrée  $x_i$ , le processus de compression peut s'écrire par :

$$t_k = \sum_{j=1}^h w_{jk}^{(2)} \sigma \left( \sum_{i=1}^n w_{ij}^{(1)} x_i + \theta_j \right), k = 1, 2, \dots, q \quad (3.35)$$

Où la couche d'étranglement force le réseau BNN à compresser les entrées (variables surveillées).

Etape de décompression : la couche d'étranglement produit les sorties du réseau par décompression selon les équations suivantes :



$$\hat{x}_k = \sum_{j=1}^h w_{jk}^{(4)} \sigma \left( \sum_{i=1}^q w_{ij}^{(3)} t_i + \theta_i \right), k = 1, 2, \dots, N_1 \quad (3.36)$$

Avec :

- $n$  est le nombre de neurone dans la couche d'entrée.
- $h$  est le nombre de neurone dans la couche de compression.
- $q$  est le nombre de neurone dans la couche d'étranglement.
- $w$  sont les poids des neurones.
- $\theta_i$  est la seuil de l' $i$ ème neurone.
- $\sigma$  c'est la fonction de transfert (dans les couches de compression décompression  $\sigma$  est une fonction sigmoïdale, alors que dans la couche d'étranglement et de sortie  $\sigma$  est linéaire,).

L'algorithme d'apprentissage repose sur le principe d'optimisation dont le but de minimiser itérativement une fonction coût (qui, dans le cas d'un apprentissage supervisé, constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées) en modifiant les poids (qui sont aléatoirement initialisés avant l'apprentissage) en fonction du gradient de la fonction coût.

Il faut noter que l'erreur quadratique  $E(k)$  obtenue à partir de la différence obtenue sur les  $n$  neurones de sortie :

$$E = \sum_{n=1}^N \sum_{i=1}^n (x_i^n - \hat{x}_i^n)^2 \quad (3.37)$$

### 3.7 Exemple d'illustration

Sur cet exemple de synthèse, nous appliquons les différents principes du diagnostic à base d'analyse statistique multivariées présentées précédemment dans la

section 3.6, page 48, pour tester leurs efficacités et pour mettre en évidence leurs caractéristiques, leurs avantages et inconvénients.

$$x_1 = \sin(t) + e_1 \quad (3.38a)$$

$$x_2 = 2t^2 + 4t + e_2 \quad (3.38b)$$

$$x_3 = t^3 - 2t^2 + e_3 \quad (3.38c)$$

Avec,  $t = [t_1, t_2, \dots, t_{512}] \in [0, 1.022]$

L'exemple contient 3 variables, où  $e_1, e_2$  et  $e_3$  sont des bruits aléatoires uniformément  $N(0, 0.0002)$ , le nombre d'observations  $k$  est égale à 1024 et le niveau de confiance  $\alpha$  est égale à 95%. L'hypothèse la plus importante pour construire un modèle à partir de l'analyse en composantes principales est la nécessité du jeu de données, pour cela et à partir du système à 3 variable deux jeux de données sont considérés, chacun d'eux contient 512 observations. En revanche, l'ensemble des deux jeux de données sont associées à des conditions de fonctionnement normal, le premier jeu est considéré pour la construction du modèle, et le second pour la phase de validation. Dans ce qui suit, nous allons voir comment détecter et localiser les défauts qui peuvent apparaître dans le fonctionnement d'un tel processus. Les figures présentées dans cette section illustrent la méthodologie de la détection et l'isolation de défauts (supposé provenant des capteurs) en utilisant dans un premier temps l'approche basée sur l'ACP multi-échelles puis l'approche basée sur un réseau de neurones artificiels sous forme de mémoires auto-associatives avec une couche d'étranglement.

Les figures 3.3 et 3.4 présentent l'évolution de l'indice de détection SPE du système à trois variables sous un fonctionnement normal utilisant respectivement,




FIGURE 3.3 – SPE dans des conditions normales calculé par la méthode l'ACP multi-modèles.




FIGURE 3.4 – SPE dans des conditions normales utilisant un réseau AANN.




FIGURE 3.5 – SPE filtré en fonctionnement normal en utilisant l’approche l’ACP multi-modèles.

l’ACP multi-échelles et l’approche BNN, où le signal SPE illustré dans les deux figures est en dessous de sa limite de contrôle correspondante ( donc aucun défaut affecte le système).




FIGURE 3.6 – SPE filtré en fonctionnement normal basé sur un réseau AANN.

Nous constatons dans les figures 3.3 et 3.4 des pics en dessus des limites de contrôles qui peuvent provoquer des fausses alarmes, pour cela nous avons appliqué un filtre EWMA (Exponentially Weighted Moving Average) afin de réduire ces fausses alarmes, comme présenté dans les figures 3.5 et 3.6.

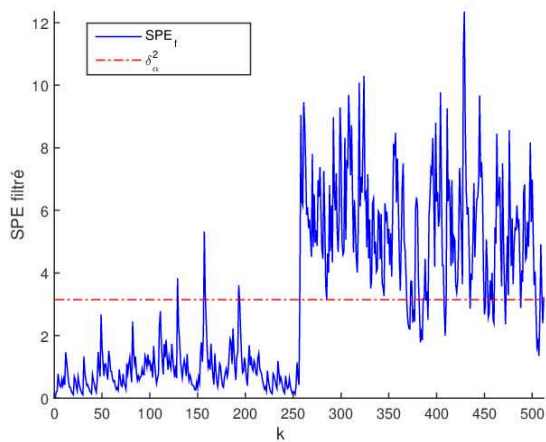


FIGURE 3.7 – SPE filtré avec défaut biais basé sur l’approche l’ACP multi-modèles.




FIGURE 3.8 – SPE filtré avec défaut biais utilisant un réseau AANN.

Malgré la présence du filtre EWMA nous remarquons toujours un nombre de pics inférieur (fausses alarmes) en dessus des limites de contrôles. En raison de ce nombre de fausses alarmes rencontrées dans la phase de détection lors de l'utilisation d'une limite de contrôle constante ou fixe obtenue à partir des stratégies conventionnelles à base des deux approches du diagnostic (ACP multi-échelles et BNN), il est claire à observer l'intérêt de l'utilisation de la limite de contrôle adaptative proposée dans la présente thèse, qui consiste à éviter les fausses alarmes n'ont pas été filtrées par l'EWMA.




FIGURE 3.9 – SPE filtré avec défaut dérive utilisant la méthode l'ACP multi-modèles.

Afin d'observer l'impact des défauts, nous supposons que différents types de défauts sont affectés à une des variables du système. Pour cela, dans un premier temps un défaut affecte la variable  $x_3$  à l'instant  $t = 257$ , ce défaut représente une forme biais d'amplitude égale à 3 % de la variable en cause, puis un défaut de forme dérive affecte la même variable avec déviation de 0.9 % de la variable en défaut dans le même instant  $t$ .

Nous constatons que l'indice de détection filtré  $SPE_f$  a dépassée sa limite de contrôle correspondante comme montre les figures 3.7 et 3.8 pour le défaut biais, 3.9 et 3.10 pour le cas d'un défaut dérive.




FIGURE 3.10 – SPE filtré avec défaut dérive basé sur l’approche AANN.




FIGURE 3.11 – Localisation du défaut bias par contribution à l’indice de détection SPE calculé par la méthode l’ACP multi-modèles




FIGURE 3.12 – Localisation du défaut biais par contribution en utilisant un réseau AANN.

Après avoir détecté le défaut, il est nécessaire d'isoler la variable en cause. Dans cette section en se basant sur la méthode de calcul des contributions des variables à l'indice de détection SPE nous montrons les deux figures 3.11 et 3.12 dont le but de localiser le défaut biais, les figures 3.13 et 3.14 pour localiser le défaut dérive, utilisant respectivement l'ACP multi-modèles et l'approche BNN.




FIGURE 3.13 – Localisation du défaut dérive par calcul de contributions basée sur l'ACP multi-modèles.






FIGURE 3.14 – Localisation du défaut dérive par contribution basée l’approche AANN.

Tandis que, l’isolation basée sur la méthode des contributions à l’indice  $SPE$  qui est basée sur un calcul dans un instant donné  $k$  peut commettre des erreurs de localisation, ainsi pour l’identification. Ces stratégies traditionnelles restent incapables d’identifier la nature des défauts détectés par  $SPE$ .

### 3.8 Conclusion :

Dans ce chapitre, nous avons présenté une synthèse bibliographique des outils d’analyse des données statistique multivariées en l’occurrence l’ACP linéaire. Concernant la sélection du nombre optimal de CPs à retenir, nous avons détaillé les deux critères les plus efficaces, l’un basé sur la minimisation de l’erreur de reconstruction et l’autre consiste à étudier le pourcentage cumulé de la variance.

L’approche standard de l’ACP traite seulement les relations linéaires entre les variables, alors on est incapable d’obtenir une représentation compacte des données réelles (non-linéaires) par l’utilisation de cette version. L’analyse en composantes principales multi-échelles et celle à base d’un réseaux de neurones auto associatif son les extensions non linéaire les plus populaire de l’ACP et les plus généralement utilisés dans le domaine du diagnostic, ont été expliquées et étudiées dans ce

chapitre.

Plusieurs méthodes pour détecter et localiser les variables en défaut utilisant l'analyse en composantes principales. L'indice SPE pour la détection d'anomalies est le plus utilisé dans le cadre de l'ACP. Cependant, l'approche par calcul des contributions des variables à l'indice de détection SPE est l'approche largement utilisée dans la littérature pour la localisation de défauts par l'ACP. un filtre EWMA est appliqué au résidus pour réduire les fausses alarmes et d'améliorer la détection des défauts.

Dans ce chapitre, nous avons conclu que la méthode de calcul des contributions présente des inconvénients, cette méthode consiste à localiser la défaillance en calculant les contributions des variables à l'indice de détection dans un instant déterminé  $t_k$ . En plus cette méthode reste incapable d'identifier la nature du défaut.

Pour surmonter ces inconvénients, nous proposons la méthode de calcul des indices de validité des capteurs (SVIs) qui repose sur le principe de reconstruction de la variable défaillante en éliminant le défaut. Cette méthode présente une excellente variante de la méthode de calcul des contributions des variables.

Pour ces raisons, l'objectif du prochain chapitre est dédié à la présentation de la Limite de Contrôle Adaptative (LCA) dans la phase de détection. La stratégie proposée est renforcée dans la phase d'isolation et identification par la méthode de calcul des indices de validité (SVIs) pour surmonter les inconvénients de la méthode des contributions, ce qui permet de détecter, isoler et identifier le défaut d'une façon plus efficace et plus rapide afin de garantir le bon fonctionnement du système.

## CHAPITRE 4

### CONTRIBUTION AU CONTRÔLE STATISTIQUE DES PROCESSUS NON LINÉAIRES

#### 4.1 Introduction

Aujourd'hui, l'augmentation de la disponibilité des capteurs dans le domaine de surveillance et du diagnostic des processus industriels a conduit à des exigences plus sévères sur la capacité précoce de la détection, l'isolation et l'identification des défauts capteurs, spécialement lorsque la procédure de surveillance se base sur les informations obtenues à partir des capteurs. Donc, la surveillance ou le contrôle à l'aide des mesures précises est très utile pour améliorer la performance du processus et garantir la bonne qualité de la production.

Dans la littérature, les outils statistiques multivariés ont été largement utilisés dans le domaine de surveillance des processus. Parmi les méthodes de contrôle les plus populaires à base d'analyse statistiques multivariées : l'analyse en composantes principales (ACP) [11–13] est la méthode la plus importante et souvent plus utilisée dans la surveillance, l'ACP sert comme modèle de référence sur le processus concerné, par rapport à la quelle des nouvelles données du processus peuvent être comparées [3]. Cependant, plusieurs extensions non linéaires récentes de cette méthode ont été proposées comme l'ACP multi-échelles, L'ACP à Noyau et l'ACP non linéaire (ACPNL) à base de réseau de neurones artificiels [14], [15], [16].

Généralement, les méthodes traditionnelles de surveillance des processus industriels se basent souvent sur l'hypothèse gaussienne (les données du processus suivent une distribution gaussienne d'une valeur moyenne  $\mu$  et de variance  $\sigma$ ) ce qui conduit à obtenir une limite supérieur de contrôle (Upper control limit UCL ) comme seuil constante où un taux relativement élevé de fausses alarmes est généré. Cependant,

ce type de contrainte ne peut pas être satisfait dans la pratique car la plus part des processus industriels couvrent souvent plusieurs modes de fonctionnement.

Donc, en pratique les variables des processus industriels suivent approximativement un mélange de distributions gaussiennes multiples  $(\mu_j, \sigma_j)$  en raison de la non-linéarité des processus réels, ce qui donne un comportement multi-modal ; par conséquent une limite supérieur de contrôle adaptative est nécessaire pour améliorer la performance des processus industriels. Dans ce contexte, nous proposons une stratégie robuste de surveillance basée sur le modèle de mélanges gaussiens (Gaussian mixture model GMM) pour extraire  $m$  modes normaux caractérisés par  $m$  composantes gaussiennes  $(\mu_j, \sigma_j)$  durant des conditions de fonctionnement normales [59, 60].

Dans ce travail, un réseau de neurones à couche d'étranglement amélioré (Enhanced bottleneck neural network EBNN) est utilisé pour estimer les variables à surveiller, en même temps les classer en  $m$  classes (modes) selon leurs taux de probabilités d'appartenance aux  $m$  modes de fonctionnement déjà extraits par GMM. Par rapport aux réseaux de neurones auto-associatifs (Auto-associative neural networks AANNs) classiques qui peuvent être utilisés uniquement pour estimer les variables à surveiller, le réseau EBNN proposé n'est pas limité à l'estimation des variables, mais aussi capable de fournir une classification supervisée des variables à surveiller. Ensuite, une estimation non paramétrique de la densité de probabilité (Kernel density estimation KDE) des SPEs (locaux) de chaque sous-groupe (classe ou mode) est adoptée dont le but de calculer des limites de contrôles locales (constantes) des différents modes de fonctionnement [15, 59, 61, 62].

Par conséquent, une Limite de Contrôle Adaptative (Adaptive control limit ACL) est obtenue grâce à une somme pondérée : des taux de probabilités de  $m$  modes (estimés par les  $m$  neurones de la couche de sortie du réseau EBNN, dédiée à la classification) et  $m$  limites de contrôle locales (constantes)  $UCL_j^{(KDE)}$  de chaque indice  $SPE_j$ .

La Limite de Contrôle Adaptative obtenue est associée avec le SPE globale ( $k$ ), ce qui permet d'améliorer significativement les performances de surveillance, de réduire les fausses alarmes et de fournir une détection rapide en cas d'une déviation prévue du processus, par rapport à la limite de contrôle traditionnelle.

Dans la phase d'isolation des défauts, un calcul des contributions à l'indice de détection SPE est utilisé pour isoler le capteur défectueux. Ensuite et afin de surmonter l'inconvénient de la méthode de localisation par calcul de contributions, nous avons réalisé avec succès la méthode des indices de validité des capteurs (SVIs), qui repose sur l'élimination du défaut sur le SPE en reconstruisant la variable défaillante [8, 17]. La figure 4.2 montre le cycle de surveillance de la stratégie GMM-EBNN proposée.

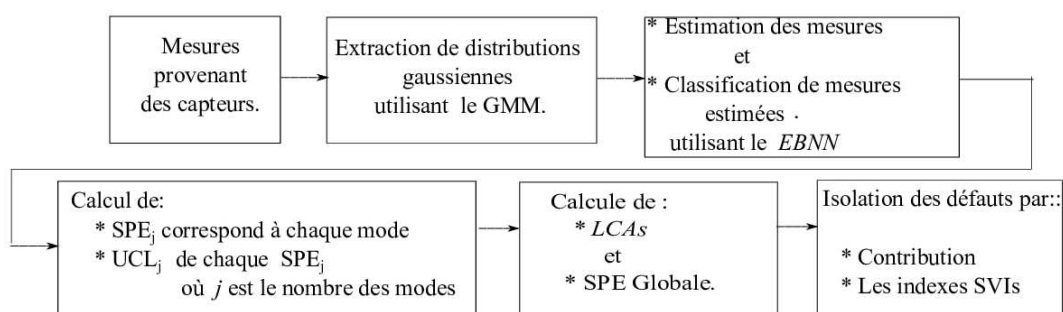


FIGURE 4.1 – Cycle de surveillance de processus.

## 4.2 Modèle de mélanges gaussiens

Un modèle de mélange gaussiens (usuellement abrégé par l'acronyme anglais GMM : Gaussian Mixture Model) sert à modéliser statistiquement une distribution d'une variable aléatoire (phénomènes physiques sous-jacents) sous forme d'une somme de plusieurs gaussiennes (appelées noyaux). Il s'agit alors de déterminer la variance, la moyenne et l'amplitude de chaque gaussienne. Ces paramètres sont optimisés selon un critère de maximum de vraisemblance pour s'approcher le plus possible à la distribution recherchée. Cette procédure se fait le plus souvent itérati-

vement via l'algorithme maximisation de l'espérance ( Expectation-Maximization EM).

L'utilisation de la densité des mélanges gaussiens est motivée par deux interprétations. Premièrement, les composantes gaussiennes individuelles sont interprétées pour représenter certains modes ou classes de fonctionnement, ces classes reflètent certains phénomènes sous-jacents ayant généré des données ; par exemple, hydrologique ou biologique dans le cas des stations du traitement de l'eau. Deuxièmement, une densité de mélange gaussiennes est présentée pour fournir une approximation de la distribution sous-jacente, à long terme de l'échantillon d'observations collectées à partir des processus industriels.

Dans les modèles de mélanges, fréquemment utilisés en classification, on considère qu'un échantillon de données suit, non pas une loi de probabilité usuelle, mais une loi dont la fonction de densité est une densité de mélange gaussiens. En effet, durant les conditions normales d'un tel processus, des modes de fonctionnement normaux multiples peuvent être caractérisés par un mélange de composantes gaussiennes, ce qui permet de donner pour chaque composante, des taux de probabilités antérieures ou des pourcentages d'appartenance de chaque variable par rapport à chaque mode [63, 64]. Les fonctions des densités de probabilités du GMM sont équivalentes à une somme pondérée des densités de probabilités de toutes les composantes gaussiennes comme s'est présenté ci-dessous :

$$p(x|\Lambda) = \sum_{j=1}^K \beta_j g(x|\lambda_j) \quad (4.1)$$

Où  $x$  est un échantillon des mesures de  $\ell$ -dimension,  $\beta_j$  est la probabilité antérieure de la  $j$ ème composante gaussienne et  $g(x|\lambda_j)$  représente la densité de probabilité multi-variée de la  $j$ ème composante. Pour chaque composante, les paramètres du modèle doivent être estimés sont  $\beta_j$  et  $\lambda_j = \{\mu_j, \sigma_j\}$ , ce dernier contient un vecteur des valeurs moyennes  $\mu_j$  et une matrice de covariances  $\sigma_j$ . Durant l'appren-

tissage du modèle, la fonction log-likelihood suivante est utilisée comme fonction d'objectif pour estimer les paramètres :

$$\log L(x|\Lambda) = \sum_{i=1}^N \log \left( \sum_{j=1}^K \beta_j g(x_i|\lambda_j) \right) \quad (4.2)$$

Avec  $x_i$  c'est  $i$ 'ème échantillon d'apprentissage parmi les  $N$  mesures totales. Le modèle de mélange gaussiens peut être estimé par l'algorithme E-M à partir de la procédure itérative suivante :

- E-étape : calcul de la probabilité postérieure de  $i$ 'ème échantillon d'apprentissage  $x_i$  à la  $s$ 'ème itération

$$P^{(s)}(m_j|x_i) = \frac{\alpha_j^{(s)} g(x_i|\lambda_j^{(s)})}{\sum_{l=1}^K \beta_l^{(s)} g(x_i|\lambda_l^{(s)})} \quad (4.3)$$

Où  $m_j$  représente la  $j$ 'ème composante gaussienne.

- M-étape : mise à jours des paramètres du modèle à la  $(s+1)$ 'ème itération

$$\mu_j^{(s+1)} = \frac{\sum_{i=1}^N P^{(s)}(m_j|x_i) x_i}{\sum_i P^{(s)}(m_j|x_i)} \quad (4.4)$$

$$\sigma_j^{(s+1)} = \frac{\sum_{i=1}^N P^{(s)}(m_j|x_i) (x_i - \mu_j^{(s+1)})(x_i - \mu_j^{(s+1)})^T}{\sum_i P^{(s)}(m_j|x_i)} \quad (4.5)$$

$$\beta_j^{(s+1)} = \frac{\sum_{i=1}^N P^{(s)}(m_j|x_i)}{N} \quad (4.6)$$

Il faut noter que le nombre  $m$  des composantes gaussiennes correspond au nombre des modes de fonctionnement dans des conditions normales [65]. Après l'extraction des différents modes de fonctionnement normaux, l'étape suivante consiste à désigner le modèle EBNN.

### 4.3 Réseau EBNN

Les réseaux de neurones auto-associatifs sont des outils puissants pour le contrôle des systèmes dynamiques non linéaires. Dans ce travail une topologie améliorée d'un réseau de neurone artificiel (Enhanced Bottleneck Neural Network EBNN) à cinq couches, avec trois couches cachées : une couche de compression (ou de codage), une couche d'étranglement et une couche de décompression est utilisée [12, 66, 67]. Une fois la structure du réseau EBNN est défini, il reste de déterminer le nombre des neurones nécessaires dans chaque couche cachée, généralement ce nombre est déterminé par la méthode de validation croisée. En outre, les réseaux de neurones artificiels sont des outils très efficaces pour la classification, pour cette raison  $M$  neurones sont ajoutés à la couche de sortie du réseau EBNN formant un sous-réseau (Artificial Neural Network Classifier ANNC) dédié à la classification des variables estimées selon leurs taux de probabilités de distributions. L'ANNC inclus dans la couche de sortie est utilisé en raison de son aptitude d'extraire (par classe) les composantes de distributions gaussiennes des variables surveillées, voire la figure 4.2

L'apprentissage du réseau EBNN devient comme suit : Etape de compression (Codage) : pour un vecteur d'entrée  $x_i$ , le processus de compression peut s'écrire par :

$$t_k = \sum_{j=1}^h w_{jk}^{(2)} \sigma \left( \sum_{i=1}^n w_{ij}^{(1)} x_i + \theta_i \right), k = 1, 2, \dots, q \quad (4.7)$$

Etape de décompression : la couche d'étranglement produit les sorties du réseau






FIGURE 4.2 – Structure BNN pour l'estimation et la classification des variables.

par décompression selon les équations suivantes :

$$\hat{x}_k = \sum_{j=1}^h w_{jk}^{(4)} \sigma \left( \sum_{i=1}^q w_{ij}^{(3)} t_i + \theta_i \right), k = 1, 2, \dots, N_1 \quad (4.8)$$

$$\hat{\rho}_m = \sum_{j=1}^h w_{jk}^{(4)} \sigma \left( \sum_{i=1}^q w_{ij}^{(3)} t_i + \theta_i \right), k = 1, 2, \dots, m \quad (4.9)$$

Avec :

- $n$  est le nombre de neurones dans la couche d'entrée.
- $h$  est le nombre de neurones dans la couche de compression.
- $q$  est le nombre de neurones dans la couche d'étranglement.
- $w$  sont les poids des neurones.
- $\theta_i$  est la seuil de l' $i$ ème neurone.
- $m$  est le nombre de modes.

–  $\sigma$  c'est la fonction de transfert.

Il faut noter que dans les couches de compression et décompression la fonction de transfert  $\sigma$  est une fonction sigmoïdale, dans la couche d'étranglement et de sortie  $\sigma$  est linéaire, exceptionnellement, la partie dédiée à la classification dans la couche de sortie, la fonction de transfert est log-sigmoïdale dont le but de générer des probabilités postérieur variant entre 0 et 1.

L'algorithme du gradient descendant est adopté pour l'apprentissage des réseaux AANN [68, 69]. En effet, les valeurs optimales sont calculées d'une façon itérative en changeant les poids  $\omega_{ji}$  et les seuils  $\theta_i$  (aléatoirement initialisés avant l'apprentissage) selon le gradient descendant pour assurer que la différence entre la sortie idéale et l'entrée désirée est minimale, ce qui conduit à arrêter le processus d'apprentissage. Cette différence est calculée par :

$$E = \sum_{n=1}^N \sum_{i=1}^n (x_i^n - \hat{x}_i^n)^2 + \sum_{n=1}^N \sum_{j=1}^m (\rho_j^n - \hat{\rho}_j^n)^2 \quad (4.10)$$

Où :

–  $N$  est le nombre d'itérations.

–  $n$  est le nombre de neurones dans la couche de sortie de la partie estimation.

–  $m$  est le nombre de neurones (de modes) dans la couche de sortie de la partie classification.

Les variables de la partie estimation :

–  $x_i^n$  est la  $n$  valeur désirée de l' $i$ ème sortie du neurone.

–  $\hat{x}_i^n$  est la  $n$ ème valeur actuelle de l' $i$ ème sortie d'un tel neurone.

Les variables de la partie classification :

–  $\rho_j^n$  est le taux de probabilité calculé par GMM de la  $j$ ème mode.

–  $\hat{\rho}_j^n$  est la sortie actuelle de le  $j$ ème neurone correspond à le  $j$ ème mode.

Il faut noter que le nombre de neurones dans la couche de sortie de la partie classification est correspond au nombre de modes extraits.

#### 4.4 Calcul du SPE

La différence entre les variables d'entrée du réseau EBNN et leurs estimations peut être utilisée comme un indice de détection pour juger l'état de fonctionnement du processus, cette différence est souvent appelée l'erreur. le diagnostic est l'évaluation d'un état de fonctionnement d'un tel processus donné, cet état est comparé avec un état du modèle empirique qui sert comme référence, si la différence est non nulle, il s'agit donc d'une déviation de fonctionnement normal du processus. Dans le domaine de l'automatique, l'indice de détection SPE(k) utilisant l'erreur  $e(k)$  possède une importance fondamentale pour la surveillance des processus, en raison de son indicateur en cas de changement dans la structure de corrélation des variables. Son expression à l'instant  $k$  est donnée par l'équation suivante :

$$SPE(k) = e(k)e(k)^T \quad (4.11)$$

Où ;

$$e(k) = x(k) - \hat{x}(k) \quad (4.12)$$

Une fois les variables du processus à surveiller sont estimées et classées en  $m$  sous-groupes (modes) par EBNN selon leurs pourcentages d'appartenance  $\rho_j$  aux modes de distributions gaussiennes  $(\mu_j, \sigma_j)$ , dans la phase off-line : il faut noter qu'un calcul de  $m$   $SPE_j$  locaux (par conséquence  $m$  limites de contrôle locales

$UCL_j$ ) est nécessaire dans le but de calculer la Limite de Contrôle Adaptative (LCA). Cette dernière est obtenue à partir de la somme pondérée des  $m$  limites de contrôle locales  $UCL_j$  (qui sont constantes) et les pourcentages d'appartenance aux différents modes (taux des probabilités des distributions)  $\rho_j$  estimés par les neurones de la couche de sortie du réseau EBNN (dédiés pour la classification).

Dans la phase on-line : le SPE(k) globale (multimodal) assure une détection rapide et efficace en cas de déviation par rapport à LCA dans l'espace résiduel global. Le processus est considéré dans un état de fonctionnement anormal à l'instant  $k$ ème si le SPE(k) global :

$$SPE(k) > LCA^{(KDE)} \quad (4.13)$$

avec  $LCA^{(KDE)}$  est la Limite de Contrôle Adaptative du SPE(k) global basée sur la méthode d'estimation non paramétrique par noyau (Kernel Density Estimation).

#### 4.4.1 Calcul des limites de contrôle locales basées sur KDE

La méthode d'estimation non paramétrique par noyau (Kernel density estimation KDE) est un outil très puissant pour l'estimation non paramétrique de la fonction de densité de probabilité d'une variable aléatoire en tout point du support. Étant donné une matrice de  $\ell$  variables et  $n$  observations  $\{x_1, x_2, \dots, x_n\}^T \in R^{n \times \ell}$ , une estimation générale de la fonction de densité  $f(x)$  peut être définie par :

$$\hat{f}(x, H) = \frac{1}{\ell} \frac{1}{|H|^{(n+1)/2}} \sum_{i=1}^n K[H^{-1/2}(x - x_i)H^{-1/2}] \quad (4.14)$$

Avec,

-  $H \in R^{n \times n}$  est la fenêtre glissante (ou la bande passante).

- $|H|$  est le déterminant de  $H$ .
- $K(\cdot)$  est la fonction noyau.

La densité en un point  $x$  est estimée par la proportion d'observations  $x_1, x_2, \dots, x_n$  qui se trouvent à proximité de  $x$ . Pour cela, on trace une fenêtre centrée en  $x$  et dont la largeur est gouvernée par un paramètre de lissage ; on compte ensuite le nombre d'observations qui appartiennent à cette fenêtre. Cette estimation, qui dépend du paramètre de lissage, présente de bonnes propriétés statistiques.

La méthode du noyau consiste à retrouver la continuité : pour cela, on remplace la fenêtre centrée par une gaussienne centrée en  $x$ . Plus une observation est proche du point de support  $x$  plus la courbe en cloche lui donnera une valeur numérique importante. À l'inverse, les observations trop éloignées de  $x$  se voient affecter une valeur numérique négligeable. L'estimateur est formé par la somme (ou plutôt la moyenne) des courbes en cloche.

$K(\cdot)$  est choisi comme la densité d'une fonction gaussienne standard :

$$k(x) = (2\pi)^{-n/2} \exp\left(-\frac{1}{2}x^T x\right) \quad (4.15)$$

La question critique pour déterminer  $\hat{f}(x, H)$  est la fenêtre  $H$ . Dans le but de déterminer  $H$ , il faut d'abord déterminer sa structure. Généralement, il existe trois structures possibles :

- (1) une matrice symétrique avec  $n(n+1)/2$  paramètres  $h_{rj}^2$ , par exemple, dans laquelle  $h_{jr}^2 = h_{rj}^2$
- (2) une matrice diagonale avec uniquement  $\ell$  paramètres,  $H = \text{diag}(h_1^2, h_2^2, \dots, h_\ell^2)$
- (3) une matrice diagonale avec un paramètre  $H^2 I$ , où,  $I$  est une matrice unitaire.

Selon [70] la première structure est la plus efficace, mais elle est irréaliste en termes de temps et de calcul, tandis que la troisième structure est la plus simple

mais peut causer des problèmes dans certaines situations en raison de la perte de précision. La deuxième structure sera étudiée comme un compromis du premier et troisième cas, et une sélection optimale de la fenêtre (matrice) sera utilisée [71].

L'approche *KDE*, donc est capable d'estimer la fonction de densité de probabilité (Probability Density Function PDF) sous-jacente des indices  $SPE_j$ . Alors, les limites de contrôles locales  $UCL_j^{(KDE)}$  peuvent être obtenues à partir de la fonction de densité de probabilité du  $SPE_j$  avec un niveau de confiance  $\alpha$  en résolvant l'équation suivante :

$$\int_{\alpha}^{UCL_j^{(KDE)}} P(SPE_j) dSPE_j = \alpha, j = 1, 2, \dots, m \quad (4.16)$$

Où,

- $P(SPE_j)$  est la fonction de densité de probabilité du  $SPE_j$  en fonctionnement normal.
- $\alpha$  le niveau de confiance.
- $SPE_j$  est le  $j$ ème indice local.

Par conséquent, le KDE est une approche bien établie pour estimer le PDF, en particulier pour une variables aléatoire comme  $SPE$  qui est univariée.

#### 4.5 Calcul de la limite de contrôle adaptative (LCA)

Une fois les limites de contrôles locales  $UCL_j^{KDE}$  (qui sont constantes) de chaque  $SPE_j^{(\ell)}$  ainsi que les taux de probabilités d'appartenance de chaque mode sont calculés, une Limite de Contrôle Adaptative peut être obtenue à partir de la formule suivante :

$$LCA = \sum_{j=1}^m \left( UCL_j^{(KDE)} \rho_j(k) \right), k = 1, 2, \dots, n \quad (4.17)$$

Où,

- $\rho_j$  sont les taux des probabilités des distributions du  $j$ ème mode.
- $n$  est le nombre d'observations.
- $m$  est le nombre des modes gaussiens calculés par GMM correspondent au modes de fonctionnement dans des conditions normales.

Il faut noter que, la taille de l'indicateur  $SPE$  multimodal (global) est égale à la somme des dimensions de  $m$  indices  $SPE_j$  locaux. Cependant, l' $LCA$  doit être associée avec l'indice  $SPE$  multimodal (globale) pour assurer la détection rapide du défaut.

#### 4.6 Isolation et identification par calcul des indices de validité des capteurs

Cette partie est dédiée à l'isolation et l'identification des défauts capteurs basée sur la reconstruction, ce principe consiste à reconstruire la mesure en défaut utilisant le réseau EBNN déjà entraîné dans des conditions de fonctionnement normal.

Cependant, l'isolation et l'identification sont effectuées en calculant les indicateurs  $SPE_j$  de chaque mesure ( $j = 1, 2, \dots, N$  : nombre des capteurs) après la reconstruction de toutes les mesures [8, 17]. Il faut noter que la reconstruction de la mesure en cause élimine ou corrige le défaut, nous rappelons aussi que la  $j$ ème  $SPE$  de la mesure reconstruite sera au-dessus de sa Limite de Contrôle Adaptative ( $SPE_j(k) < LCA$ ) par contre les autres variables seront toutes au dessous de leurs  $LCA_j$  [43].

La mesure reconstruite peut être obtenue itérativement par estimation et ré-estimation (ré-injection) par le réseau EBNN jusqu'à la convergence comme indiqué

par la figure 4.3.




FIGURE 4.3 – Reconstruction principe.

Le principe de reconstruction consiste à corriger le capteur en défaut en reconstruisant sa mesure en se basant sur le modèle EBNN déjà obtenu ainsi les autres mesures de tout les capteurs, la procédure est répétée pour chaque capteur. l'isolation est effectuée en comparant les indices de validité des capteurs SVIs avant et après la reconstruction. les SVIs sont les mesures de la performance des capteurs que devraient avoir une gamme normalisée indépendamment du nombre des composantes principales dans la couche d'étranglement, perturbations ou défauts [8,17]. les SVI peuvent être calculés par la formule suivante :

$$\eta_j^2 = \frac{SPE}{SPE_j} \quad (4.18)$$

Où  $SPE$  est l'erreur quadratique de prédiction global calculée avant la reconstruction et  $SPE_j$  est le  $j$ ème erreur quadratique de prédiction calculé après la reconstruction [72–74].



## 4.7 Conclusion

Dans ce chapitre nous avons présenté une nouvelle stratégie de surveillance et de diagnostic des défauts, en combinant l'algorithme GMM avec le réseau EBNN, ce qui permet d'obtenir une Limite de Contrôle Adaptative (LCA), afin de détecter les défauts provenant des capteurs.

Pour la phase de localisation et d'identification, la méthode de calcul des SVIs a été proposée dans le but de surmonter les inconvénients de la technique de calcul des contributions.

La stratégie adoptée permet d'augmenter la rapidité de détection des défauts et de minimiser les fausses alarmes, souvent rencontrés lors de l'utilisation de la limite de contrôle classique.

Nous allons présenter dans le cinquième chapitre, les résultats de simulation à partir des tests sur le modèle BSM1 (qui sert comme système virtuel pour générer des données artificielles) ainsi sur les données historiques de la station d'épuration réelle d'Annaba.

## CHAPITRE 5

### RÉSULTATS ET DISCUSSIONS

#### 5.1 Introduction

Dans ce chapitre nous présentons une étude de simulation avec certains commentaires et interprétations sur les résultats obtenus, pour examiner l'efficacité de la stratégie GMM-EBNN proposée du diagnostic des défauts affectant des capteurs des stations d'épurations des eaux usées, en appliquant les outils étudiés dans les chapitres précédents, dans un premier temps, sur des données artificielles du benchmark BSM1 puis des données réelles de la station d'épuration d'Annaba.

Pour améliorer la performance du fonctionnement des procédés d'épurations des eaux usées et comme tous les processus industriels, la surveillance en ligne basée sur les capteurs est nécessaire. Dans ce travail, les capteurs concernés pour la surveillance sont cités dans les tableaux ci-dessous :

TABLE 5.1 – Les capteurs surveillés du BSM1.

N	Capteurs surveillés	Notation
1	Azote sous forme de nitrite et nitrate dans le <i>Bassin</i> <sub>1</sub>	$S_{NO1}$
2	Azote organique soluble biodégradable dans le <i>Bassin</i> <sub>1</sub>	$S_{ND1}$
3	Azote organique particulaire biodégradable dans le <i>Bassin</i> <sub>1</sub>	$X_{ND1}$
4	$NH_4^+ + NH_3$ dans le <i>Bassin</i> <sub>3</sub>	$S_{NH3}$
5	$NH_4^+ + NH_3$ dans le <i>Bassin</i> <sub>4</sub>	$S_{NH4}$
6	Oxygène dans le <i>Bassin</i> <sub>3</sub>	$S_{O3}$
7	Oxygène dans le <i>Bassin</i> <sub>4</sub>	$S_{O4}$
8	Azote sous forme de nitrite et nitrate dans le <i>Bassin</i> <sub>5</sub>	$S_{NO5}$
9	Azote organique soluble biodégradable dans <i>Bassin</i> <sub>5</sub>	$S_{ND5}$
10	Azote organique particulaire biodégradable dans le <i>Bassin</i> <sub>5</sub>	$X_{ND5}$

TABLE 5.2 – Les capteurs surveillés du processus réel d’Annaba.

N	Capteurs surveillés	Notation
1	Oxygène dissout dans l’influent	$S_{Oinf}$
2	Nitrites dans l’influent	$S_{NO2inf}$
3	Nitrates dans l’influent	$S_{NO3inf}$
4	Azote ammoniacal dans l’influent	$NH_{4inf}$
5	Demande Chimique en Oxygène dans l’influent	$DCOinf$
6	Oxygène dissout dans l’effluent	$S_{Oeff}$
7	Nitrites dans l’effluent	$S_{NO2eff}$
8	Nitrates dans l’effluent	$S_{NO3eff}$
9	Azote ammoniacal dans l’effluent	$NH_{4eff}$
10	Demande Chimique en Oxygène dans l’effluent	$DCOeff$

## 5.2 Test de simulation

Dans le but d’illustrer les avantages de la Limite de Contrôle Adaptative basée sur GMM-EBNN par rapport aux méthodes de surveillance traditionnelles comme l’ACPNL et ACP Multi-Echelle, nous présentons dans cette partie des résultats obtenus à partir des tests de simulation.

Cependant, les données de simulation utilisées dans les deux cas (BSM1 et station réelle) sont considérées dans un temps-sec pendant 14 jours dans des conditions de fonctionnement normales. Avec :

- 673 observations pour l’apprentissage.
- 672 observations pour la validation.

Où, la période d’échantillonnage  $T = 15min$  ce qui donne 1344 observations.

Les figures 5.1 and 5.2 montrent respectivement, le SPE des données BSM1 et celui des données réelles, durant des conditions de fonctionnement normal utilisant l’approche ACP Multi-Echelle, où la limite de contrôle est constante.

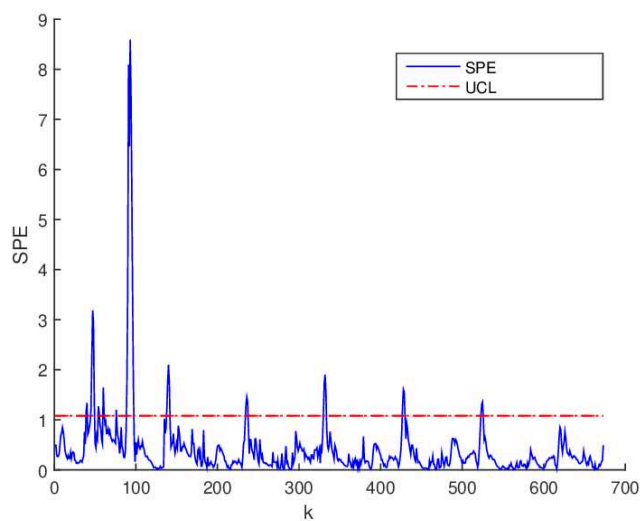


FIGURE 5.1 – SPE sous fonctionnement normal (sans défaut) utilisant ACP Multi-Echelle sur les données du BSM1.

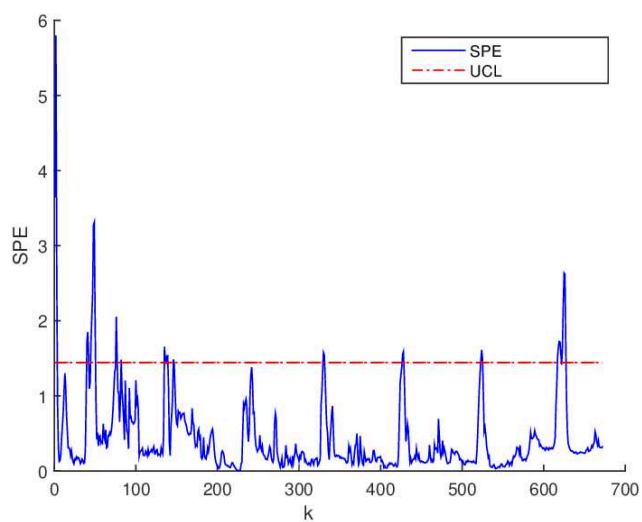


FIGURE 5.2 – SPE des données réelles durant des conditions sous fonctionnement normal utilisant ACP Multi-Echelle.

Tandis que, les figures 5.3 et 5.4 représentent l'évolution du SPE utilisant l'ACPNL basée sur les réseaux de neurones artificiels sous forme de mémoires auto-associatives avec une limite de contrôle classique UCL, respectivement, sur les données du BSM1 et sur les données réelles.




FIGURE 5.3 – SPE des données BSM1 utilisant AANN, sous fonctionnement normal.

Dans toutes les figures précédentes, le nombre élevé des fausses alarmes est clairement remarquable lors de l'utilisation de la limite de contrôle constante. Dans la partie suivante, les résultats de la stratégie GMM-EBNN proposée, basée sur une Limite de Contrôle Adaptative montrent son efficacité pour surmonter l'inconvénient du nombre élevé des fausses alarmes.

Au préalable, il faut noter qu'après la construction du réseau EBNN, une normalisation des variables à surveiller est indispensable. Un pré-traitement consiste à centrer et réduire toutes les variables de la matrice d'apprentissage et du test afin de rendre le résultat indépendant de leurs unités, en soustrayant et divisant, respectivement, la moyenne  $\mu$  et l'écart-type  $\sigma$ , de/par chaque colonne de la matrice de départ.

Dans la partie test, sous conditions de fonctionnement normal, les figures 5.5




FIGURE 5.4 – SPE des données réelles de la station d'épuration d'Annaba, avec l'approche AANN durant des conditions de fonctionnement normal.




FIGURE 5.5 – Évolution des concentrations  $S_O$ ,  $S_{NO}$  et  $S_{ND}$  du BSM1 et leurs estimations après la normalisation.




FIGURE 5.6 – Évolution des concentrations  $S_O$ ,  $S_{NO}$  et  $S_{ND}$  de la station réelle et leurs estimations après la normalisation.

et 5.6 illustrent les évolutions des variables à surveiller et leurs estimations, tandis que, les figures 5.7 et 5.8 montrent la classification des variables surveillées par mode (en fonction des taux de probabilités d'appartenance par rapport aux modes de fonctionnements) en utilisant le réseau EBNN (avec  $q=5$  composantes dans la couche d'étranglement et  $m=5$  modes de fonctionnement normal) respectivement pour les données BSM1 et les données réelles de la stations d'épuration d'Annaba.

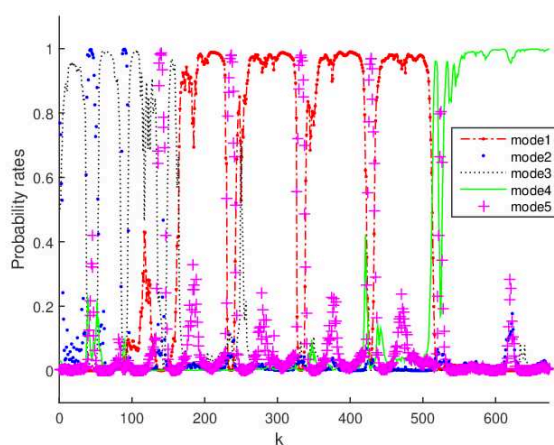


FIGURE 5.7 – Taux de probabilités d'appartenance des variables du BSM1 par rapport aux modes de fonctionnement.



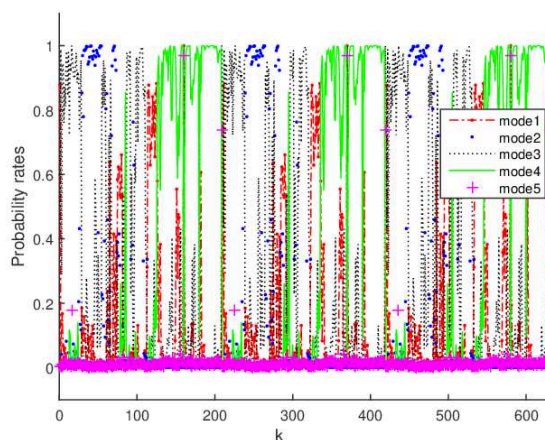


FIGURE 5.8 – Taux de probabilités d’appartenance des variables par rapport aux modes de fonctionnement des données réelles.

Il est clair à constater que les variables surveillées ont été bien reconstruites, ainsi les taux de probabilités d’appartenance de chaque variable par rapport aux modes de fonctionnement ont été bien estimés.

Les figures 5.9 et 5.10 représentent l’évolution du SPE filtré pour les données BSM1 et les données réelles, respectivement, avec une Limite de Contrôle Adaptative LCA basée sur l’approche KDE avec un niveau de confiance égale à 95% sous conditions de fonctionnement normal. Pour réduire les fausses alarmes, le filtre (exponentially weighted moving average EWMA) est utilisé pour filtrer les effets de bruits, comme montrent les figures au dessous du SPE filtré .

### 5.3 Détection de défauts capteurs

La formulation de la stratégie de surveillance et du diagnostic des processus de ce travail s’articule autour de la détection des défauts provenant des capteurs, précisément dans les stations d’épurations des eaux usées, qui peuvent être en échec partiel tel que, la dégradation de la précision en raison des effets de bruits ou de



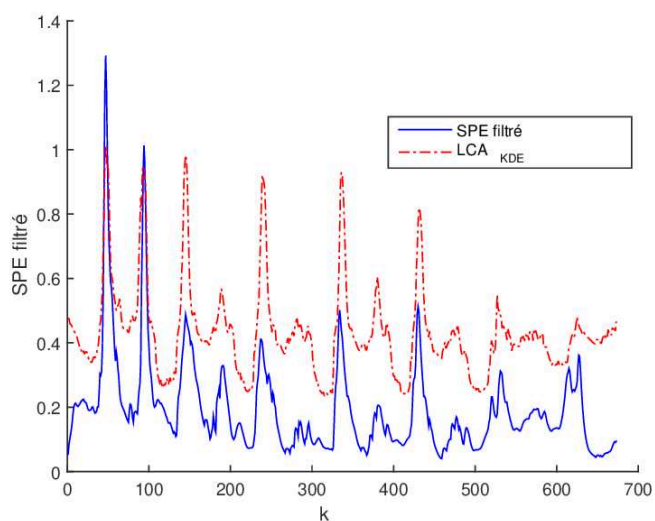


FIGURE 5.9 – SPE filtré durant un fonctionnement normal des données BSM1 avec une Limite de Contrôle Adaptative basée sur l'approche KDE.




FIGURE 5.10 – SPE filtré pour des données réelles normales (sans défaut) avec une Limite de Contrôle Adaptative basée sur l'approche KDE.

perturbations, défaut biais, ou dérive en raison de l'engorgement de la boues [75,76], définis en dessous :

**a- dégradation de la précision** : le modèle de simulation de la dégradation de précision est défini comme un processus Gaussien aléatoire, avec une valeur moyenne égale à zéro et une matrice de covariance inconnue.

**b- défaut biais** : l'évolution du défaut biais peut être caractérisée par une valeur additive, positive ou négative.

**c- défaut dérive** : cette erreur suit une déviation croissante sous forme d'un changement polynomial.

Les figures 5.11 et 5.12 montrent des résultats de dégradations de la précision testés sur les deux cas de données, BSM1 et station réel. Où, les SPEs filtrés montent plusieurs fois au dessus de leurs limites de contrôles adaptatives LCAs à partir de l'instant d'affectation du défaut  $t$ .

Le type du défaut biais peut facilement détecter par le SPE filtré, comme montre les figures 5.13 pour le BSM1 et 5.14 pour la station d'épuration réelle, le défaut affecte le capteur mesurant l'Oxygène dissout  $S_{oinf}$ , avec amplitude égale à 3 % de la mesure en défaut à un instant  $t$ .

Concernant les défauts de forme dérive, les capteurs  $S_{NO2}$  et  $N_{H4inf}$  sont affectés par des déviations de 0.9 % de la mesure en cause à partir de l'instant  $t$ , les SPEs du BSM1 et des données réelles sont au dessus de leurs limites de contrôle adaptatives (LCA) comme illustrés dans les figures 5.15 et 5.16.

Il est tout a fait claire, que les évènements anormales correspondent à la dégradation de la précision, le défaut biais et dérive sont considérés comme des dysfonctionnement reliés aux capteurs de l'Oxygène dissout, de l'azote sous formes de




FIGURE 5.11 – SPE filtré pour une dégradation de précision dans le capteur  $S_{NH}$  du BSM1.

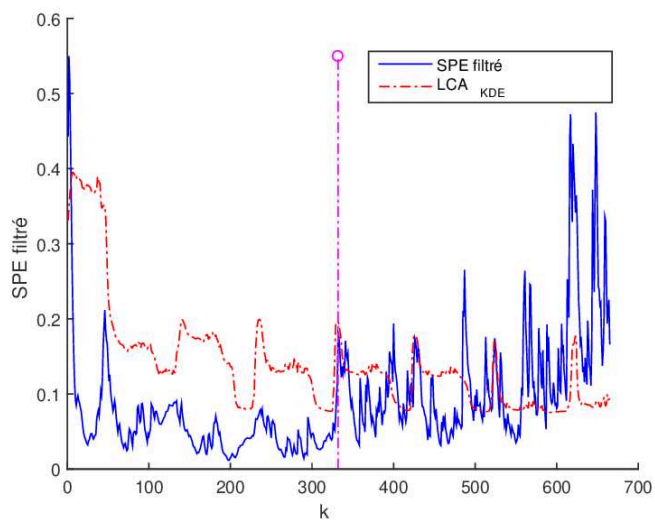


FIGURE 5.12 – SPE filtré pour une dégradation de précision dans le capteur  $S_{NHinf}$  de la station d'épuration réel.




FIGURE 5.13 – SPE filtré pour défaut biais affectant le capteur  $S_O$  du BSM1.




FIGURE 5.14 – SPE filtré d'un défaut biais affectant le capteur  $S_{Oinf}$  de la station d'épuration réelle.




FIGURE 5.15 – SPE filtré pour un défaut dérive en capteur  $S_{NO_2}$  du BSM1.




FIGURE 5.16 – SPE filtré pour un défaut dérive affectant le capteur  $N_{Hainf}$  de la station réelle.

Nitrate et de nitrite (qui sont des capteurs très importants dans les procédés d'épurations des eaux usées) sont détectés facilement à l'aide de la Limite de Contrôle Adaptative (LCA) à des instants différents selon la forme du défaut, comme indiqué dans le tableau 5.3.

Il est clair que l'indicateur SPE excède sa Limite de Contrôle Adaptative dans les deux cas de défauts capteurs biais et dérive. Cependant, dans le cas du défaut de type : dégradation de la précision, nous pouvons facilement constater que ce type de dysfonctionnement est traduit par des alarmes discontinues même en présence de la Limite de Contrôle Adaptative LCA.

TABLE 5.3 – Scénarios des faults .

Type du défaut	Dégradation de précision	Biais	Dérive
Expression du défaut	$\zeta_i = w(\mu, \sigma^2)$	$\zeta_i = const$	$\zeta_i = k1 * \epsilon_{i-1}^n + k2 * \epsilon_{i-1}^{n-1} + \dots k0.$
Défaut capteur	$Capteur(t) + (0, \sigma^2)$	$Capteur(t) + 1.2$	$Capteur(t) + 0.5t$
Temps du défaut	336	336	336
Temps de Détection	349.4 pour le BSM1 et 346.2 pour les données réelles	336.7 pour le BSM1 337.2 pour les données réelles	342.3 pour le BSM1 392.1 pour les données réelles

Dans cette phase qui concerne la détection des différents types de défauts capteurs, les résultats obtenus montrent que la performance de la stratégie GMM-EBNN proposée est très robuste, efficace, produit peu de fausses alarmes et rapide en présence des défauts. Pour l'isolation, rien n'est observé dans les figures précédentes. Pour cela, la phase suivante consiste à isoler et identifier les défauts détectés.

#### 5.4 Isolation et Identification des défauts capteurs par calcul de contributions

Une fois que le défaut est détecté, il est nécessaire de l'isoler et d'identifier sa nature. Selon l'approche de contributions à l'indice de détection SPE, comme illustré dans les figures 5.17 et 5.18 pour les données du BSM1 et celles de la station d'épuration réelle (dans le cas du défaut dérive) dans le moment de détection, le capteur  $S_O$  possède la contribution la plus élevée. En revanche, la concentration  $S_O$  présente une haute corrélation avec les autres mesures du procédé ce qui donne

des contributions élevées lors de l'utilisation de cette méthode. Par conséquence, ça provoque des erreurs de localisation des défauts. En plus, comme ça était expliqué auparavant la méthode de contributions isole le défaut mais reste incapable d'identifier sa nature.

Pour surmonter les inconvénients de méthode de contributions traditionnelle : l'isolation et l'identification via une reconstruction du défaut capteur est proposée et illustrée dans les figures ci-dessous.




FIGURE 5.17 – Isolation par la méthode de contribution à l'indice de détection SPE pour un défaut dérive affectant le capteur  $S_O$  du BSM1.

## 5.5 Isolation par reconstruction de défauts capteurs

Les figures 5.19 et 5.20 illustrent les indices de validité des capteurs (Sensor validity indexes SVIs) du BSM1 et des données de la station d'épuration réelle avant et après la reconstruction du défaut dans le cas biais. Alors que, les figures 5.21 et 5.22 concernent les SVIs dans le cas d'un défaut de forme dérive.

Dans les quelles les défauts ont été éliminés par correction de la mesure erronée en utilisant le principe de reconstruction (non linéaire). Il est tout a fait claire que le capteur corrigé est le capteur en défaut.




FIGURE 5.18 – Contributions à l'indice SPE pour Isolation un défaut dérive affectant le capteur  $S_{Oinf}$  de la station réelle.

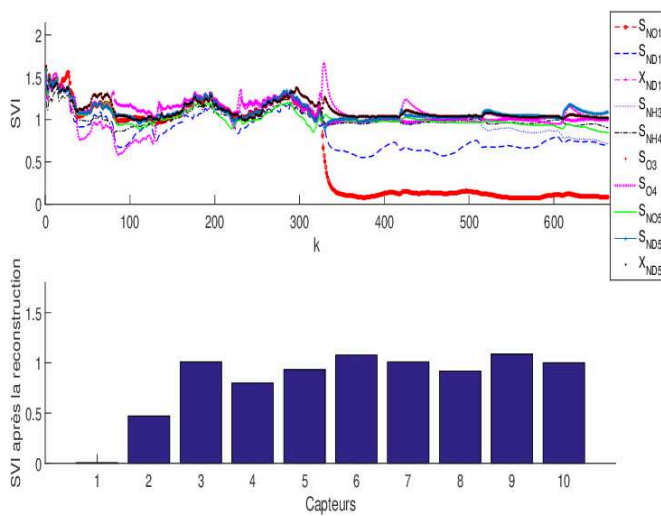


FIGURE 5.19 – Isolation par SVIs d'un défaut biais affectant un capteur  $S_{NO1}$  du BSM1.






FIGURE 5.20 – Isolation par SVIs d'un défaut biais affectant un capteur  $S_{NOinf}$  de la station réelle.




FIGURE 5.21 – Isolation par SVIs d'un défaut dérive affectant un capteur  $S_{ND1}$  du BSM1.

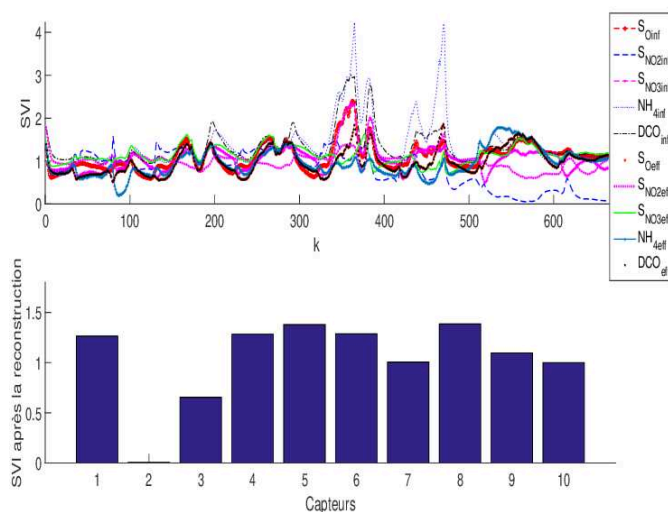


FIGURE 5.22 – Isolation par SVIs d'un défaut dérive affectant un capteur  $S_{NO2inf}$  de la station réelle.

La technique basée sur les SVIs peuvent être immédiatement afficher le défaut en-ligne dès que l'évènement anormal est détecté, ce qui permet de l'isoler et d'identifier sa nature. Les SVIs ne se limitent pas d'isoler et identifier le défaut capteur, mais peuvent aussi montrer la corrélation de la mesure corrigée (en défaut) avec les autres mesures, dans ce contexte il est claire d'observer que certains capteurs ont été influencés par la reconstruction (comme le capteur possédant la deuxième plus grande contribution, voir les figures 5.17 et 5.18) en raison de leurs corrélation élevée avec le capteur en défaut, cela peut aider l'opérateur à fournir des interprétations faisables.

il faut noter qu'il est facile de tester n'importe quel type du défaut sur n'importe quel capteur, exceptionnellement dans le cas du défaut de type : dégradation de précision, qui n'est pas identifiable par la méthode de contribution à l'indice SPE mais ça peut être réaliser par la méthode SVIs.

Finalement, l'étude comparative montre que la stratégie GMM-EBNN proposée, possède une performance supérieure, plus rapide et efficace pour la surveillance et le

diagnostic des défauts, par rapport aux méthodes traditionnelles comme l'ACP NL ou l'ACP multi-échelles, qui sont très sensibles avec la limite de contrôle classique (constante) et aussi considérées très lentes dans la détection des défauts.

## 5.6 Conclusion

Dans ce chapitre nous avons présenté les résultats de simulation obtenus en utilisant la stratégie GMM-EBNN proposée du diagnostic des défauts provenant des capteurs, basée sur une Limite de Contrôle Adaptative et associée avec l'indicateur SPE, ce qui permet de minimiser le nombre des fausses alarmes habituellement rencontrées, lors de l'utilisation de la limite de contrôle classique (constante).

Nous présentons en suite les conclusions et les perspectives des outils statistiques multivariés appliqués sur des données artificielles d'un Benchmark BSM1 et sur des données historiques d'une station d'épuration réelle.

## CONCLUSION ET PERSPECTIVES

Récemment, des lois de plus en plus strictes ont été imposées sur la qualité des eaux usées rejetées dans les effluents industriels et municipaux, dont le but de générer une limite aux produits toxiques (chimiques et organiques) qui ont causé beaucoup de dangers à la fois, sur l'environnement et l'être humain.

Cependant, l'objectif principal du traitement biologique des eaux usées est de transformer ces composés toxiques, afin de les réduire en maximum des eaux usées, où des concentrations admissibles de ces polluants nocifs sont définies par des normes européennes.

Cette préoccupation croissante de la protection de l'environnement conduit les stations d'épuration à la nécessité de fonctionner dans des conditions de fonctionnement normales, dans point de vue de l'automatique, c'est le principe de surveillance et diagnostic des défauts.

Dans cette thèse, nous avons présenté les techniques de diagnostic les plus populaires parmi les plusieurs classifications proposées par les chercheurs dans ce domaine, en particulier les méthodes d'analyse statistique multivariées basées sur le traitement de données. Tandis que, la surveillance ou le contrôle à l'aide des mesures précises (sans défauts) est très utile pour améliorer la performance des processus et garantir la bonne qualité de production.

L'ACP est l'une des méthodes de diagnostic à base d'analyse de données la plus connues. Généralement le principe de cette technique est la réduction de la dimensionnalité des données, avec perte du moins d'information possible. Pour faciliter l'analyse, cette méthode permet d'identifier les relations entre les variables

du système, afin de trouver un modèle aide par la suite de contrôler le comportement des systèmes par génération des indicateurs de défauts (résidu), en comparant le comportement donné par les variables mesurées et le comportement donné par le modèle ACP prévu.

Malheureusement, l'approche standard présentée de l'ACP traite seulement des données linéaires, donc on ne peut pas obtenir une représentation compact des données non-linéaires (des systèmes réelles) par l'utilisation de cette version. Cependant, plusieurs extensions récentes de cette méthode ont été proposées, comme l'ACP Multi-Echelle et l'ACP non linéaire (ACPNL) à base de réseau de neurones artificiels sous forme de mémoires auto-associatives à cinq couches.

L'idée principale de l'étude décrite dans ce travail concerne une proposition d'une nouvelle stratégie GMM-EBNN consiste à contrôler les processus non linéaires. La stratégie proposée combine un modèle de mélange gaussien (GMM) avec un réseau de neurones à couche d'étranglement amélioré en sa sortie (EBNN), afin d'obtenir une Limite de Contrôle Adaptative (LCA) capable de réduire les fausses alarmes habituellement générées lors de l'utilisation d'une limite de contrôle traditionnelle (constante). En revanche, le réseau EBNN proposé ne se limite pas à fournir seulement l'estimation des variable à surveiller, mais aussi estime leurs taux de probabilité d'appartenances aux différents modes de fonctionnement.

Plusieurs méthodes pour détecter et localiser les variables en défaut utilisant l'analyse en composantes principales. L'indice SPE pour la détection d'anomalies est le plus utilisés dans le cadre de l'ACP. Cependant, l'approche par calcul des contributions des variables à l'indice de détection SPE est l'approche largement utilisée dans la littérature pour la localisation de défauts par l'ACP. un filtre EWMA est appliqué au résidus pour minimiser les fausses alarmes et d'améliorer la détection des défauts.

Nous avons conclu à travers cette études que la méthode de calcul des contributions présente des inconvénients, cette méthode consiste à localiser la défaillance en calculant les contributions des variables à l'indice de détection dans un instant déterminé  $t_k$ . En plus cette méthode reste incapable d'identifier la nature du défaut. Pour surmonter ces inconvénients, nous proposons la méthode de calcul des indices de validité des capteurs ( Sensor validity indexes SVI) qui repose sur le principe de reconstruction de la variable défaillante en éliminant le défaut. Cette méthode présente une excellente variante de la méthode de calcul des contributions des variables.

En outre, la méthode SVIs basée sur la reconstruction de la mesure erronée donne un impact très important à la stratégie proposée dans la phase localisation et l'identification, où la reconstruction permet d'identifier la nature de défaut du capteur défectueux en comparant les indices de validité des capteurs avant et après la reconstruction. En revanche, Le filtre appliqué aux SVIs et SPE ajoute une caractéristique importante pour minimiser de plus le nombre de fausses alarmes, ce qui donne un meilleur taux de diagnostic par rapport aux méthodes traditionnelles généralement utilisées.

## BIBLIOGRAPHIE

- [1] D. Aguado and C. Rosen, “Multivariate statistical monitoring of continuous wastewater treatment plants,” *Engineering Applications of Artificial Intelligence*, vol. 21, no. 7, pp. 1080–1091, 2008.
- [2] L.-J. Zhao, T.-Y. Chai, and Q.-M. Cong, “Multivariate statistical modeling and monitoring of sbr wastewater treatment using double moving window mpca,” in *Machine Learning and Cybernetics, 2004. Proceedings of 2004 International Conference on*, vol. 3, pp. 1371–1376, IEEE, 2004.
- [3] C. Rosén and G. Olsson, “Disturbance detection in wastewater treatment plants,” *Water Science and Technology*, vol. 37, no. 12, pp. 197–205, 1998.
- [4] J. Alex, L. Benedetti, J. Copp, K. Gernaey, U. Jeppsson, I. Nopens, M. Pons, L. Rieger, C. Rosen, J. Steyer, *et al.*, “Benchmark simulation model no. 1 (bsm1),” *Report by the IWA Taskgroup on Benchmarking of Control Strategies for WWTPs*, 2008.
- [5] J. V. Kresta, J. F. Macgregor, and T. E. Marlin, “Multivariate statistical monitoring of process operating performance,” *The Canadian Journal of Chemical Engineering*, vol. 69, no. 1, pp. 35–47, 1991.
- [6] G. E. Box, “Some theorems on quadratic forms applied in the study of analysis of variance problems, i. effect of inequality of variance in the one-way classification,” *The annals of mathematical statistics*, pp. 290–302, 1954.
- [7] B. M. Wise and N. B. Gallagher, “The process chemometrics approach to process monitoring and fault detection,” *Journal of Process Control*, vol. 6, no. 6, pp. 329–348, 1996.

- [8] R. Dunia, S. J. Qin, T. F. Edgar, and T. J. McAvoy, "Identification of faulty sensors using principal component analysis," *AIChE Journal*, vol. 42, no. 10, pp. 2797–2812, 1996.
- [9] Y. Tharrault, *Diagnostic de fonctionnement par analyse en composantes principales : Application à une station de traitement des eaux usées*. PhD thesis, Institut National Polytechnique de Lorraine-INPL, 2008.
- [10] M.-F. Harkat, *Détection et localisation de défauts par analyse en composantes principales*. PhD thesis, Institut National Polytechnique de Lorraine-INPL, 2003.
- [11] D. Dong and T. J. McAvoy, "Nonlinear principal component analysis based on principal curves and neural networks," *Computers and Chemical Engineering*, vol. 20, no. 1, pp. 65–78, 1996.
- [12] M. A. Kramer, "Nonlinear principal component analysis using autoassociative neural networks," *AIChE journal*, vol. 37, no. 2, pp. 233–243, 1991.
- [13] Z. Ge and Z. Song, "Process monitoring based on independent component analysis- principal component analysis (ica- pca) and similarity factors," *Industrial & Engineering Chemistry Research*, vol. 46, no. 7, pp. 2054–2063, 2007.
- [14] B. R. Bakshi, "Multiscale pca with application to multivariate statistical process monitoring," *AIChE journal*, vol. 44, no. 7, pp. 1596–1610, 1998.
- [15] Z. Shijian and X. Yongmao, "Multivariate statistical process monitoring using robust nonlinear principal component analysis," *Tsinghua Science and Technology*, vol. 10, no. 5, pp. 582–586, 2005.
- [16] L. Xiong, J. Liang, and Q. Jixin, "Multivariate statistical process monitoring of an industrial polypropylene catalyzer reactor with component analysis and



- kernel density estimation1,” *Chinese Journal of Chemical Engineering*, vol. 15, no. 4, pp. 524–532, 2007.
- [17] R. Dunia, S. J. Qin, T. F. Edgar, and T. J. McAvoy, “Use of principal component analysis for sensor fault identification,” *Computers and Chemical Engineering*, vol. 20, pp. S713–S718, 1996.
- [18] R. R. T. E. Greenberg and e. L. S. Clesceri, *Standard methods for the examination of water and wastewater*. 1985.
- [19] G. Gottschalk, *Bacterial Metabolism*. Springer-Verlag New York, 1987.
- [20] J. Arundel, *Sewage and Industrial Effluent Treatment : a practical guide*. Blackwell Publishing, 2000.
- [21] P. L. D. Ekama, G. A. and G. V. R. Marais, “Procedures for determining influent cod fractions and the maximum specific growth rate of heterotrophs in activated sludge systems.,” *Water Science and Technology*, vol. 18, no. 6, pp. 91–114, 1986.
- [22] J. G. M. Henze and W. E. A. Gujer, “Activated sludge model n.1 (asm1),” *IAWPRC Scientific and Technical Report N.1. IWAPRC Publishing, London,* 1987.
- [23] S. W. P. Sotomayor, O. A. Z. and C. Garcia, “A reference model for evaluating control strategies in activated sludge waste treatments plants,” *Revue de sciences de lâEau*, vol. 15, pp. 543–556, 2002.
- [24] S. W. P. Sotomayor, O. A. Z. and C. Garcia, “A simulation benchmark to evaluate the performance of advanced control techniques in biological wastewater treatment plants,” *Brazilian Journal of Chemical Engineering*, vol. 18, no. 1, pp. 81–101, 2001.

- [25] U. Jeppsson and M.-N. Pons, “The cost benchmark simulation model—current state and future perspective,” 2004.
- [26] J. Copp, “The cost simulation benchmark : description and simulator manual,” *European Cooperation in the Field of Scientific and Technical Research*, 2001.
- [27] G. G. P. Takács, Imre and D. Nolasco, “A dynamic model of the clarification-thickening process,” *Water research*, vol. 25, no. 10, pp. 1263–1271, 1991.
- [28] e. a. Henze, Mogens, “Activated sludge model no. 2d, asm2d,” *Water Science and Technology*, vol. 39, no. 1, pp. 165–182, 1999.
- [29] M. Blanke and T. F. Lootsma, “Adaptive observer for diesel fault detection in ship propulsion benchmark,” in *Control Conference (ECC), 1999 European*, pp. 4608–4613, IEEE, 1999.
- [30] R. Isermann and P. Ballé, “Trends in the application of model based fault detection and diagnosis of technical processes,” in *IFAC Proceedings*, vol. 29, pp. 6325–6336, 1996.
- [31] F. Szigeti, “A differential-algebraic condition for controllability and observability of time varying linear systems,” in *Decision and Control, 1992., Proceedings of the 31st IEEE Conference on*, pp. 3088–3090, IEEE, 1992.
- [32] F. Sallem, *Détection et isolation de défauts actionneurs basées sur un modèle de l'organe de commande*. PhD thesis, Université de Toulouse, Université Toulouse III-Paul Sabatier, 2013.
- [33] M. Combacau, *Commande et surveillance de systèmes à événements discrets complexes : application aux ateliers flexibles de production manufacturière*. PhD thesis, Thèse de Doctorat, Université de Toulouse 3, 1991.

- [34] H. Derbel, *Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de systèmes dynamiques hybrides*. PhD thesis, Université Joseph-Fourier-Grenoble I, 2009.
- [35] G. Zwingelstein, "Diagnostic des défaillances. traité des nouvelles technologies," *série Diagnostic et Maintenance, Hermes (Wiesb.)*, 1995.
- [36] A. S. Willsky, "A survey of design methods for failure detection in dynamic systems," *Automatica*, vol. 12, no. 6, pp. 601–611, 1976.
- [37] R. Isermann, "Process fault detection based on modeling and estimation methods—a survey," *Automatica*, vol. 20, no. 4, pp. 387–404, 1984.
- [38] M. Basseville, "Detecting changes in signals and systems—a survey.," *Automatica*, vol. 24, no. 3, pp. 309–326, 1988.
- [39] S. Dash and V. Venkatasubramanian, "Challenges in the industrial applications of fault diagnostic systems," *Computers & chemical engineering*, vol. 24, no. 2-7, pp. 785–791, 2000.
- [40] J. Chen and R. J. Patton, *Robust model-based fault diagnosis for dynamic systems*, vol. 3. Springer Science & Business Media, 2012.
- [41] S. J. Qin, "Data-driven fault detection and diagnosis for complex industrial processes," *IFAC Proceedings Volumes*, vol. 42, no. 8, pp. 1115–1125, 2009.
- [42] S. Valle, W. Li, and S. J. Qin, "Selection of the number of principal components : the variance of the reconstruction error criterion with a comparison to other methods," *Industrial & Engineering Chemistry Research*, vol. 38, no. 11, pp. 4389–4401, 1999.
- [43] M.-F. Harkat, G. Mourot, and J. Ragot, "An improved pca scheme for sensor fdi : Application to an air quality monitoring network," *Journal of Process Control*, vol. 16, no. 6, pp. 625–634, 2006.

- [44] T. Kourti and J. MacGregor, "Multivariate spc methods for monitoring and diagnosing of process performance," in *Proceedings of PSE*, vol. 94, pp. 739–746, 1994.
- [45] R. E. S. Miller, Paige and C. E. Heckler, "Contribution plots : a missing link in multivariate quality control," *Applied mathematics and computer science*, vol. 8, no. 4, pp. 775–792, 1998.
- [46] e. a. Teppola, Pekka, "Principal component analysis, contribution plots and feature weights in the monitoring of sequential process data from a paper machine's wet end," *Chemometrics and Intelligent Laboratory Systems*, vol. 44, no. 1-2, pp. 307–317, 1998.
- [47] S. P. G. Westerhuis, Johan A. and A. K. Smilde, "Generalized contribution plots in multivariate statistical process monitoring," *Chemometrics and intelligent laboratory systems*, vol. 51, no. 1, pp. 95–114, 2000.
- [48] M. Kano, S. Hasebe, I. Hashimoto, R. Strauss, B. R. Bakshi, and H. Ohno, "Contribution plots for fault identification based on the dissimilarity of process data," in *AIChE Annual Meeting*, pp. 12–17, 2000.
- [49] A. Conlin, E. Martin, and A. Morris, "Confidence limits for contribution plots," *Journal of Chemometrics*, vol. 14, no. 5-6, pp. 725–736, 2000.
- [50] T. Hastie and W. Stuetzle, "Principal curves," *Journal of the American Statistical Association*, vol. 84, no. 406, pp. 502–516, 1989.
- [51] A. R. Webb, "An approach to non-linear principal components analysis using radially symmetric kernel functions," *Statistics and computing*, vol. 6, no. 2, pp. 159–168, 1996.
- [52] J. Morlet, "Sampling theory and wave propagation," in *Issues in acoustic Signalâimage processing and recognition*, pp. 233–261, Springer, 1983.

- [53] K. A. Kosanovich and M. J. Piovoso, "Pca of wavelet transformed process data for monitoring," *intelligent data analysis*, vol. 1, no. 2, pp. 85–99, 1997.
- [54] B. B. Hubbard, *Ondes et ondelettes : la saga d'un outil mathématique*. Pour la science Belin, 1995.
- [55] I. DAUBECHIES, "Orthonormal bases of compactly supported wavelets," *Communications on pure and applied mathematics*, vol. 41, no. 7, pp. 909–996, 1988.
- [56] I. Daubechies, "Ten lectures on wavelets," *CBMS-NSF regional conference series in applied mathematics*, vol. 61, no. 4, 1991.
- [57] A. Cohen, *Détection et diagnostic des fautes dans des systèmes complexes par approches multichelles*. PhD thesis, Université d'Angers, 2015.
- [58] S. G. Mallat, "A theory for multiresolution signal decomposition : the wavelet representation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 11, no. 7, pp. 674–693, 1989.
- [59] Q. P. He and J. Wang, "Fault detection using the k-nearest neighbor rule for semiconductor manufacturing processes," *IEEE Transactions on Semiconductor Manufacturing*, vol. 20, no. 4, pp. 345–354, 2007.
- [60] H. Yu, "A just-in-time learning approach for sewage treatment process monitoring with deterministic disturbances," in *Industrial Electronics Society, IECON 2015-41st Annual Conference of the IEEE*, pp. 000059–000064, IEEE, 2015.
- [61] L. Dobos and J. Abonyi, "On-line detection of homogeneous operation ranges by dynamic principal component analysis based time-series segmentation," *Chemical Engineering Science*, vol. 75, pp. 96–105, 2012.

- [62] G. Verdier and A. Ferreira, "Fault detection with an adaptive distance for the k-nearest neighbors rule," in *Computers & Industrial Engineering, 2009. CIE 2009. International Conference on*, pp. 1273–1278, IEEE, 2009.
- [63] J. Yu, "A particle filter driven dynamic gaussian mixture model approach for complex process monitoring and fault diagnosis," *Journal of Process Control*, vol. 22, no. 4, pp. 778–788, 2012.
- [64] J. Yu, "A nonlinear kernel gaussian mixture model based inferential monitoring approach for fault detection and diagnosis of chemical processes," *Chemical Engineering Science*, vol. 68, no. 1, pp. 506–519, 2012.
- [65] M. A. T. Figueiredo and A. K. Jain, "Unsupervised learning of finite mixture models," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 24, no. 3, pp. 381–396, 2002.
- [66] G. Wang and Y. Cui, "On line tool wear monitoring based on auto associative neural network," *Journal of Intelligent Manufacturing*, vol. 24, no. 6, pp. 1085–1094, 2013.
- [67] Y. Huang, "Advances in artificial neural networks—methodological development and application," *Algorithms*, vol. 2, no. 3, pp. 973–1007, 2009.
- [68] A. Dev, B. J. Kröse, L. Dorst, and F. A. Groen, "Recovering patch parameters from the optic flow with auto associative neural networks," in *Intelligent Autonomous Systems : IAS-4 : Proceedings of the International Conference Karlsruhe, Germany March 27-30, 1995*, p. 213, IOS Press, 1995.
- [69] C. Jung, S.-W. Ban, S. Jeong, and M. Lee, "Input and output mapping sensitive auto-associative multilayer perceptron for computer interface system based on image processing of laser pointer spot," in *International Conference on Neural Information Processing*, pp. 185–192, Springer, 2010.

- [70] Q. Chen, R. Wynne, P. Goulding, and D. Sandoz, "The application of principal component analysis and kernel density estimation to enhance process monitoring," *Control Engineering Practice*, vol. 8, no. 5, pp. 531–543, 2000.
- [71] J. Liang, "Multivariate statistical process monitoring using kernel density estimation," *Developments in Chemical Engineering and Mineral Processing*, vol. 13, no. 1-2, pp. 185–192, 2005.
- [72] K. Bouzenad, M. Ramdani, N. Zermi, and K. Mendaci, "Use of nlpca for sensors fault detection and localization applied at wtp," in *Computer and Information Technology (WCCIT), 2013 World Congress on*, pp. 1–6, IEEE, 2013.
- [73] K. Bouzenad, M. Ramdani, and A. Chaouch, "Sensor fault detection, localization and reconstruction applied at wwtp," in *Control and Fault-Tolerant Systems (SysTol), 2013 Conference on*, pp. 281–287, IEEE, 2013.
- [74] A. Chaouch, K. Bouzenad, and M. Ramdani, "Enhanced multivariate process monitoring for biological wastewater treatment plants," *Int. J. Electr. Energy*, vol. 2, pp. 131–137, 2014.
- [75] C. Yoo, K. Villez, I. Lee, S. Van Hulle, and P. A. Vanrolleghem, "Sensor validation and reconciliation for a partial nitrification process," *Water Science and Technology*, vol. 53, no. 4-5, pp. 513–521, 2006.
- [76] C. K. Yoo, K. Villez, S. W. Van Hulle, and P. A. Vanrolleghem, "Enhanced process monitoring for wastewater treatment systems," *Environmetrics : The official journal of the International Environmetrics Society*, vol. 19, no. 6, pp. 602–617, 2008.

## REFERENCES PERSONNELLES

### Communications internationales

- K. Bouzenad, M. Ramdani, N. Zermi, and K.Mendaci "Use of NLPCA for sensors fault detection and localization applied at WTP in Computer and Information" *in Computer and Information Technology (WCCIT), 2013 World Congress on*, pp. 16, IEEE, 2013.

- K. Bouzenad, M. Ramdani and A. Chaouch " Sensor fault detection, localization and reconstruction applied at WWTP" *In Proceedings of the 2013 Conference on Control and Fault-Tolerant Systems (SysTol) Nice, France*, pp. 281–287. IEEE, 2013.

- A. Chaouch, K. Bouzenad and M. Ramdani " Enhanced Multivariate Process Monitoring for Biological Wastewater Treatment Plants" *Int. J. Electr. Energy*, vol. 2, pp. 131–137, 2014.

### Publications internationales

- K. Bouzenad, M. Ramdani, N. Zermi, and K.Mendaci "Use of NLPCA for sensors fault detection and localization applied at WTP" *Journal of E -Technology*, vol. 4, no.3, pp.138–148, 2013.

- A. Chaouch, K. Bouzenad and M. Ramdani " M. Enhanced Multivariate Process Monitoring for Biological Wastewater Treatment Plants" *International Journal of Electrical Energy*, vol. 2, no.2, pp. 131–137, 2014.



- K. Bouzenad and M. Ramdani "Multivariate Statistical Process Control Using Enhanced Bottleneck Neural Network" *Algorithms*, vol. 10 no. 2, pp. 49, 2017.