

وزارة التعليم العالي و البحث العلمي
جامعة باجي مختار- عنابه

BADJI MOKHTAR-ANNABA UNIVERSITY

UNIVERSITE BADJI MOKHTAR-ANNABA

FACULTÉ : Science de l'Ingéniorat

DÉPARTEMENT : Electronique

MEMOIRE

Présenté en vue de l'obtention du diplôme de : MASTER

INTITULE

**CONTROLE STATISTIQUE MULTIVARIE A BASE DE MODELE
NEURONAL EPARSE**

Domaine : Sciences et Technologie

Filière : AUTOMATIQUE

Spécialité : Automatique et Systèmes

Par

BEN TALEB LIAMINE

DEVANT LE JURY

- ◆ **Président : DR BENMOUSSA SAMIR — Grade : MCA - Université Badji Mokhtar Annaba**
- ◆ **Directeur de mémoire : PR RAMDANI MESSAOUD - Grade : PROFESSEUR - Université Badji Mokhtar Annaba**
- ◆ **Examineur : DR BOULEBTATECH BRAHIM - Grade : MCB - Université Badji Mokhtar Annaba**

Année 2019/2020

ملخص

إن المنافسة في الأسواق العالمية تفرض على المؤسسات التجارية الإنتاج لاستمرار بنوعية ذو جودة راقية و بتكلفة أقل مع احترام القوانين الطبيعية و بدا من الضروري احترام مبدأ التأمين على المنتجات مع المراقبة الدائمة لكل حادث مفاجئ أو عطل . في العادة تتم مراقبة العمل الإنتاجي علة أساس المعلومات مثل (ACP) التي تعتمد على قانون (قوس) بعلاقة مترابطة وخطية لكن هذه الوسيلة محدودة مع التقدم العلمي و التكنولوجي و المراقبة تتطلب تحديات كبيرة علة الميدان .

لذا اقترحنا وسيلة تكنولوجية من نوع آخر بتسمية (SSAE) لتحقيق و إعادة بناء جهاز الاستشعار المعيب جهاز المراقبة يعتمد وسيلة الإحصاء (Q) أو بتسمية (SPE) للكشف على الحوادث المفاجئة و الغير طبيعية. نتائج التجارب التي اعتمدت على معطيات حقيقية بمعالجة مياه صالحة للشرب أكدت فعالية الوسائل المقترحة عليهما.

Résumé :

La compétitivité sur le marché exige que les companies commerciales produisent en continue avec une bonne qualité et à coût réduit, tout en respectant la nature. Pour atteindre ces objectifs, il est impératif de maintenir les processus en sécurité par un suivi de leurs performances, en détectant à temps tous les événements anormaux.

D'habitude, la surveillance de processus à base de données telle que l'ACP suppose que les données de mesure suivent la loi de Gauss et que la corrélation est linéaire. Cependant, cette contrainte est très restrictive puisque la plupart des procédés sont multi-modaux et non linéaires. Bien que plusieurs algorithmes d'ACP nonlinaires ont été proposés, le design de bonnes statistiques de suivi de performances reste un grand défi.

Etant motivé par les progrès récents de l'apprentissage profond (deep learning) dans différents domaines, ce travail propose une stratégie de maîtrise statistique multivarié basé sur le modèle neuronal épars auto-encodeur "Stacked Sparse Auto-encoder" (SSAE) pour valider et reconstruire les capteurs défaillants.

La procédure de surveillance (monitoring) utilise la statistique-Q, aussi appelée SPE (Squared Prediction Error) pour détecter les événements anormaux avec une limite de confiance basée sur les estimateurs à noyaux KDE (kernel density estimate), et l'indice de validité de capteur basé sur le principe de reconstruction pour l'identification de défauts. Les résultats expérimentaux utilisant un système simulé et des données réelles d'un procédé de traitement de l'eau potable montrent clairement l'efficacité de l'approche proposée.

Mots-Clés : Analyse intelligente de données, ACP, sous-espace, Indice de détection, limite de Confiance, Reconstruction, indice de validité de capteur.

Abstract :

The strong competition on the market requires that the economic companies produce continuously with high quality at lower costs, while being environmental friendly. The ultimate way to achieve these objectives is to keep the safety and availability of the plants by monitoring their performances and detecting any malfunctions at the early stages and then finding and removing the factors causing the abnormal events. Traditional data-driven process monitoring such as PCA often assumes that process measurements follow a Gaussian distribution and are linearly correlated. However, this constraint is very conservative because many real processes frequently span multiple operating states. Although nonlinear PCA algorithms have been proposed it is still very challenging to design adequate statistics to monitor new performances.

Motivated by the recent progress of the deep learning in different areas, this work proposes an improved multivariate statistical process monitoring scheme based on the Stacked Sparse Auto-encoder (SSAE) to validate and reconstruct faulty sensor data.

The monitoring procedure uses the Squared Prediction Error (SPE) index to detect abnormal events with an adaptive non-parametric confidence limit derived from the kernel density estimate (KDE), and an improved sensor validity index (SVI) based on the reconstruction principle to identify the defective sensor. The experimental results using both synthetic and actual data from a drinking-water treatment plant, show clearly that the proposed scheme is able to detect and identify sensor failures.

Key-Words : Intelligent Data analysis, PCA, Subspace, Detection, Control limit, Reconstruction, Sensor Validity Index (SVI).

REMERCIEMENTS

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

Je remercie vivement mon encadreur Prof. Ramdani pour ses conseils constructifs. Mes remerciements s'adressent également à ceux qui m'ont aidé à réaliser ce travail dont je n'est pas cité leurs noms.

Je dédie ce travail à mes parents et à toute ma famille

TABLE DES MATIÈRES

REMERCIEMENTS	iv
DÉDICACE	v
TABLE DES MATIÈRES	vi
LISTE DES FIGURES	1
NOTATION	2
INTRODUCTION	4
CHAPITRE 1 : TECHNIQUES DE DIAGNOSTIC	6
1.1 Concepts de base	6
1.2 Techniques de diagnostic	7
1.2.1 Approches relationelles	8
1.2.2 Les méthodes à base de modèles	8
1.2.3 Les méthodes à base de données	9
CHAPITRE 2 : MÉTHODES STATISTIQUES DE PROJECTION EN	
SOUS ESPACES	10
2.1 Introduction	10
2.2 Notions de base	11
2.3 Modélisation par ACP Linéaire	12
2.4 Choix de la dimension de l'espace réduit	15
2.4.1 Variance de l'erreur de reconstruction (VER) :	15
2.4.2 Pourcentage cumulé de la variance (PCV) :	17
2.5 Détection par ACP Linéaire	19
2.5.1 Statistique de Hotelling (T^2) :	19
2.5.2 Statistique SPE (Q) :	19
2.6 Localisation par ACP linéaire	21
2.6.1 Localisation par calcul de contribution :	21

2.6.2	Indice de validité des capteurs (SVI) :	22
CHAPITRE 3 : MODÈLE NEURONAL ÉPARSE AUTO-ENCODEUR		23
3.1	Introduction	23
3.2	Le modèle neuronal éparse autoencodeur (SSAE)	25
3.3	Détection d'anomalie (Anomaly detection)	26
3.3.1	Limites de confiance ou de contrôle	27
3.4	Identification de défaut	28
3.4.1	Courbes de contribution (Contribution Plots)	28
3.4.2	Principe de Reconstruction Nonlinear	28
3.4.3	Indice de validité de capteur	29
CHAPITRE 4 : RÉSULTATS ET DISCUSSIONS		30
4.1	Introduction	30
4.2	Cas d'études	30
4.2.1	Système de simulation	30
4.2.2	Application sur un procédé de traitement de l'eau potable	32
CONCLUSION		38
BIBLIOGRAPHIE		39

LISTE DES FIGURES

1.1	Les trois classes de défaillances.	7
1.2	Classification des techniques de diagnostic.	7
1.3	Procédure de diagnostic à base de modèle.	8
1.4	Principe de diagnostic à l'aide d'un observateur.	9
2.1	Structure d'un tableau de données.	11
2.2	Représentation géométrique des observations.	12
2.3	Nuage centré sur le centre de gravité.	13
2.4	Selection du nombre de CPs à retenir par le critère est VER.	17
2.5	Selection du nombre de CPs par PCV.	17
2.6	Etapas pour la détermination d'un modèle ACP.	18
3.1	Principe de Reconstruction	28
4.1	SPE : données du mode normal.	31
4.2	SPE : données avec un défaut de capteur	32
4.3	Isolation de défaut en utilisant la méthode de contribution (normalized contribution plots) pour un défaut dans le capteur 3	33
4.4	Isolation de défaut en utilisant la méthode de contribution (normalized contribution plots) pour un défaut dans le capteur 3	33
4.5	Identification de défaut en utilisant l'indice de validité de capteur (Sensor Validity Index, SVI) pour un défaut dans le capteur 3.	34
4.6	Les unités de traitement de l'eau potable.	35
4.7	SPE : Donnée de la condition normale	36
4.8	SPE : Cas de condition anormale	36
4.9	Identification de défaut par contribution (normalized contribution plots) pour le modèle neuronal SSAE	37
4.10	Les indices de validité des capteurs (sensor validity index, SVI) des capteurs de l'eau brute et traitée en utilisant le modèle neuronal éparsé, SSAE	37

NOTATION

$X \in \mathfrak{R}^{n \times m}$	matrice de données.
n	nombre d'échantillons mesurés.
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}	échantillons du vecteur variable.
\bar{v}_j	moyenne de la jème variable.
σ_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.
λ	valeurs propres de la matrice de corrélation.
Λ	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}	ℓ premiers vecteurs propres.
\tilde{P}	$m - \ell$ derniers vecteurs propres.
\hat{t}_j	ℓ 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.
ξ_j	jème colonne de la matrice unitaire (direction de défauts).
T_{lim}^2	seuil de confiance de l'indicateur d'Hotelling.
δ^2	seuil de confiance de l'indicateur SPE.
$\eta_j^2(k)$	indice de validité des capteurs.

AMDEC	Analyse des Modes de Défaillance, de leurs Effets et de leurs Criticités.
ADD	Arbre De Défaillances.
RDF	Reconnaissance De Formes.
RDN	Réseaux De Neurone artificiels.
ACP	Analyse en Composantes Principales.
CPs	Composantes Principales.
EP	Espace Principale.
ER	Espace Résiduel.
PCV	Pourcentage Cumulé de la Variance.
PRESS	Validation croisée.
VER	Variance de l'Erreur de Reconstruction.
SPE	Critère de l'Erreur quadratique de prédiction.
T2	Critère d'Hotelling .
EWMA	Exponentially Weighted Moving Average.
SVI	Sensor Validity Index.
ACPNL	Analyse en Composantes Principales Non Linéaire.
MLP	Multi-Layer Perceptron.
RBF	Radial Basis Function.
ITN	Input Training Network.
AAMLP	Auto-Assosiative Multi-Layer Perceptron.

INTRODUCTION

Les progrès réalisés dans les technologies de l'information et de communication ont permis de mettre en oeuvre des stratégies de surveillance et de suivi de performances des systèmes technologiques, en particulier les unités de production industriels. En effet, le principe de base de diagnostic est basé sur l'analyse des informations issues du processus à surveiller.

En général, il est possible de classer les méthodes de diagnostic en trois grandes familles : **à base de modèles analytiques** (en comparant l'évolution de l'écart entre le modèle et le processus réel), les **méthodes relationnelles** (fondées sur une connaissance a priori des défauts et de leurs effets des systèmes), **à base de données**).

Dans le cadre de notre projet, on s'intéresse à la troisième catégorie, c-à-d à base de données historiques pour concevoir des systèmes de contrôle statistique de surveillance, où les performances de ces méthodes sont étroitement liées à la pertinence des indicateurs de défauts et à l'analyse des mesures. Cette étude porte sur l'utilisation d'un réseau neuronal éparsé autoencodeur, opérant par apprentissage profond (deep learning) et nécessitant le design d'un indice de validité de capteur (sensor validity index, SVI).

Le mémoire comporte quatre chapitres :

Le premier chapitre tente de dresser un état de l'art sur le diagnostic des processus dynamiques, il donne des généralités sur les concepts les plus utilisés dans ce domaine.

Le deuxième chapitre décrit le principe de base des méthodes statistiques de projection en sous espaces, en accordant un intérêt particulier à l'ACP linéaire afin de trouver la structure et les paramètres du modèle qui aide par la suite à la détection et la localisation des défauts. Pour la détection des défauts deux indices de

détection seront présentés, l'indice SPE *squared pridecat error* appelée aussi la statistique Q, et l'indice T2 ou la statistique de *Hotelling*. En revanche, l'identification de défauts repose sur deux méthodes : le calcul des contributions des variables à l'indice de détection, et le principe de reconstruction de variables.

Quant au troisième chapitre, il est consacré au modèle neuronal éparse qui est une extension de l'ACP linéaire où si les données à traiter présentent des comportements non linéaires, dont l'apprentissage s'effectue apprentissage en minimisant l'erreur quadratique entre les entrées et les sorties du réseau.

Enfin, le quatrième chapitre présente les résultats expérimentaux avec une application sur des données réelles d'un procédé de traitement de l'eau potable.

CHAPITRE 1

TECHNIQUES DE DIAGNOSTIC

Avec la modernisation incessante des outils de production, les systèmes technologiques deviennent de plus en plus complexes. Au même temps, la fiabilité, la disponibilité et la protection de l'environnement sont devenues de véritables enjeux pour les entreprises actuelles, ce qui justifie la nécessité de la mise en œuvre des systèmes de diagnostic bien adaptés dans le but d'améliorer les points précédents. Dans ce contexte, de nombreuses approches sont développées, en vue de la détection de défaillances et du diagnostic, par les différentes communautés de recherche en automatique. Les méthodes se différencient par rapport au type de connaissance a priori sur le processus qu'elles nécessitent. Ainsi, elles peuvent être classées, de façon générale, comme des méthodes : relationnelles, à base de modèles et des méthodes à base de données historiques.

Dans ce chapitre, on tente de définir les concepts de base relatifs au contexte général de notre travail, avec une classification des techniques de diagnostic selon la nature de la connaissance disponible sur le système à surveiller.

1.1 Concepts de base

Défaillance :

Une défaillance est l'altération ou la cessation de l'aptitude d'un ensemble à accomplir sa ou ses fonctions requises avec les performances définies dans les spécifications techniques. Les changements inattendus de comportement peuvent affecter la partie commande de procédé, comme ils peuvent affecter les paramètres ou les composantes du processus, voir la figure 1.1.

La *détection* détermine la normalité ou l'anormalité du fonctionnement du système et le *diagnostic* cherche le lien de causalité entre les symptômes observés et la défaillance [3], alors cette fonction consiste à localiser les éléments défaillants et à identifier les causes à l'origine du problème.

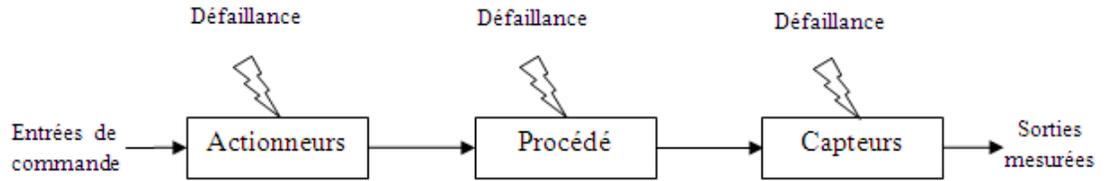


FIGURE 1.1 : Les trois classes de défaillances.

1.2 Techniques de diagnostic

Dans cette partie, nous proposons une des classifications des méthodes de diagnostic selon trois axes : les approches relationnelles, les méthodes de traitement de données et les approches à base de modèles [2]. Cette organisation est présentée dans la figure (1.2)

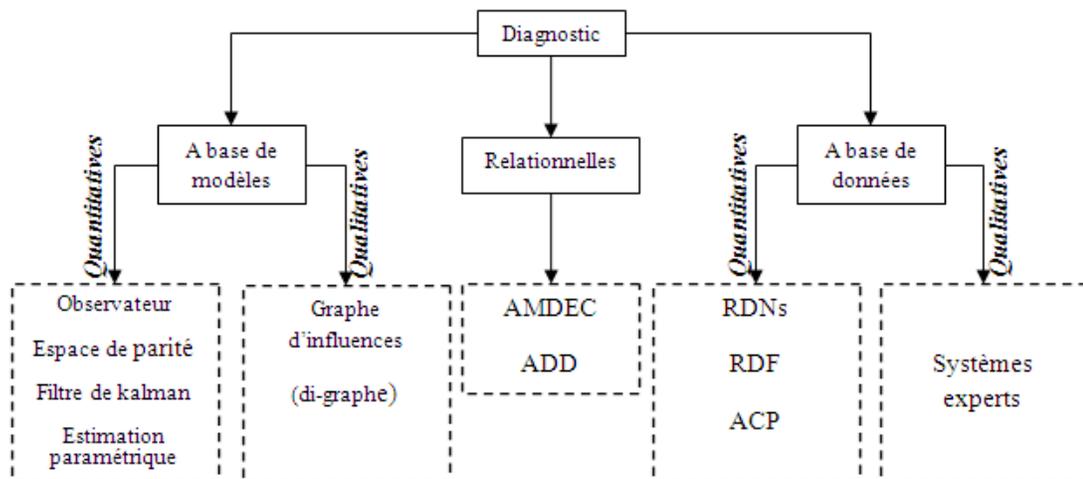


FIGURE 1.2 : Classification des techniques de diagnostic.

1.2.1 Approches relationnelles

Les approches relationnelles sont des méthodes issues du contexte de la sûreté de fonctionnement qui associe des causes à des symptômes. Elles sont basées, en général, sur des systèmes à base de règles ou de graphes avec un raisonnement, par exemple la méthode AMDEC (*Analyse des Modes de Défaillance*, et la méthode ADD (*Arbre De Défaillances*).

Ce sont des approches de diagnostic fondées sur une connaissance associative dépendante du système et sur une connaissance a priori des défauts et de leurs effets. Dans le cas des procédés complexes qui nous préoccupent, le nombre élevé de variables, de composants et de modes opératoires, rend leur utilisation peu adaptée.

1.2.2 Les méthodes à base de modèles

Ces modèles peuvent être de type quantitatif, exprimés sous forme d'équations mathématiques ou bien de type qualitatif, exprimés par exemple sous forme de relations logiques. 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.

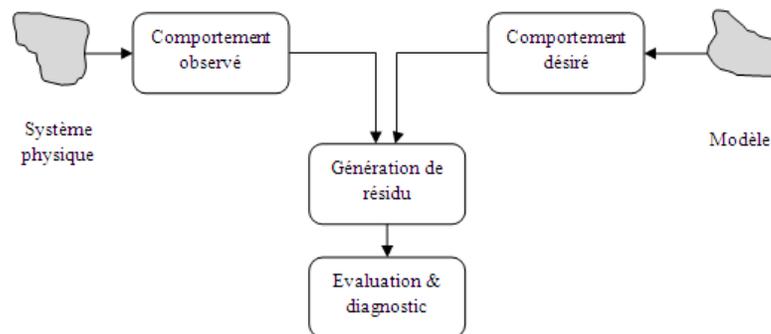


FIGURE 1.3 : Procédure de diagnostic à base de modèle.

D'habitude, le diagnostic à base de modèle peut être considéré comme un pro-

cessus séquentiel de trois étapes, comme le montre la figure 1.3, : génération de résidus, évaluation de ces résidus et logique de décision qui permet d'évaluer l'état futur système.

Diagnostic à l'aide d'observateurs :

Le principe de cette méthode est d'utiliser les erreurs d'estimation sur les sorties comme résidus. L'objectif est de construire des résidus structurés c'est-à-dire menant à la localisation des défauts.

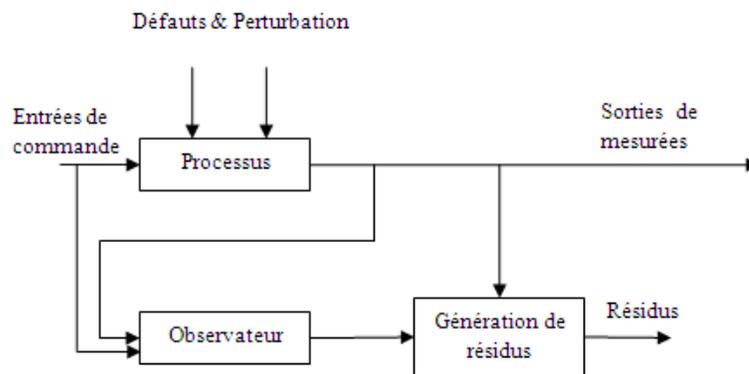


FIGURE 1.4 : Principe de diagnostic à l'aide d'un observateur.

1.2.3 Les méthodes à base de données

Ces méthodes comprennent, parmi d'autres, les méthodes statistique, d'apprentissage et de classification (ou reconnaissance de formes).

Les méthodes à base de connaissance exploitent les compétences, le raisonnement et les connaissances des experts sur le processus pour les transformer en règles, de manière à résoudre des problèmes spécifiques.

CHAPITRE 2

MÉTHODES STATISTIQUES DE PROJECTION EN SOUS ESPACES

2.1 Introduction

Parmi les méthodes statistiques de projection en sous espace, l'Analyse en Composantes principales "ACP" est une des méthodes descriptives multidimensionnelles appelées méthodes factorielles. Elle permet d'étudier simultanément les relations qui existent entre les variables, et de réduire la dimensionalité d'un ensemble de données d'une taille importante afin d'analyser et traiter ces données.

L'ACP consiste à remplacer un nombre de variables par de nouvelles variables de *dimension inférieure*, à *variance maximale*, et *non corrélées*. Ces nouvelles variables sont appelées *composantes principales* "CPs". On appelle axes principaux 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.

En général, les deux ou les trois premiers axes principaux constituent les directions de l'**espace réduit** (**sous espace des composantes principales**, \hat{S}) qui appartient à l'espace original de données. Le sous espace restant est appelé (**espace résiduel** \tilde{S}).

Dans ce qui suit, nous allons décrire :

- Le principe de la modélisation de l'*ACP linéaire* d'une façon générale,
- L'application dans le contexte spécifique de **détection et localisation** de défauts,

2.2 Notions de base

Tableau de données :

L'ACP propose à partir d'un tableau ou matrice de données, dont la structure est montrée sur la figure 2.1, une représentation géométrique permet de former ce que l'on appelle *nuage de points*, où chaque point est positionné dans un repère en fonction de ses coordonnées, voir figure 2.2.

$$\begin{array}{cccc}
 & v_1 & v_2 \longrightarrow & v_m \\
 X = & \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix} & \begin{array}{l} \vartheta_1 \\ \vartheta_2 \\ \downarrow \\ \vartheta_n \end{array}
 \end{array}$$

FIGURE 2.1 : Structure d'un tableau de données.

Variable et observation :

Chaque une des colonnes de la matrice de données est appelée **variable**, et chaque variable (ou colonne) est un vecteur contenant n échantillons ou paramètres, qui sont les valeurs numériques des variables pour chacune des observations.

Chacune des lignes de la matrice de données est appelée **observation**, c'est un vecteur-ligne de m échantillons qui sont les valeurs numériques des m variables pour cette observation.

Moyenne et variance

La moyenne d'une variable v_j où $v_j^T = [x_{1j} \ x_{2j} \ \dots \ x_{nj}]$ et $j = [1 \ \dots \ m]$

$$\bar{v}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (2.1)$$

La variance σ_j d'une variable v_j mesure des fluctuations (la dispersion) de la variable aléatoire autour de sa moyenne.

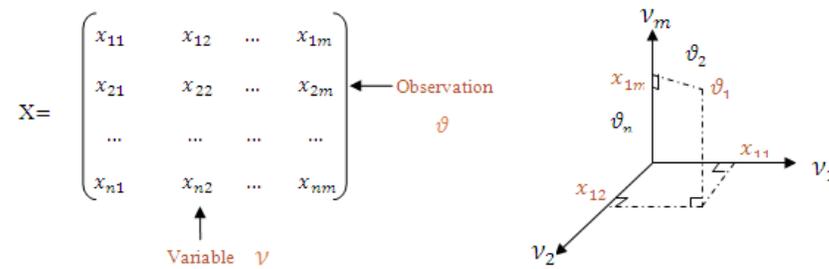


FIGURE 2.2 : Représentation géométrique des observations.

si $j = [1 \ \dots \ m]$ la variance de chaque variable a la formule suivante :

$$\sigma_j^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \bar{v}_j)^2 \quad (2.2)$$

2.3 Modélisation par ACP Linéaire

Normalisation de la matrice de données :

Soit le centre de gravité G du nuage des observations dont les coordonnées sont les valeurs moyennes des variables :

$$G = \left(\bar{v}_1 = \frac{1}{n} \sum_{i=1}^n x_{i1} \quad \bar{v}_2 = \frac{1}{n} \sum_{i=1}^n x_{i2} \quad \dots \quad \bar{v}_m = \frac{1}{n} \sum_{i=1}^n x_{im} \right) \quad (2.3)$$

Où $\frac{1}{n}$ est le poids des observations.

Et alors on va travailler sur le tableau des données centrées, voir figure 2.3.

Ensuite, la réduction de la matrice de données centrée par la transformation suivante :

$$X_j = \frac{X_C}{\sigma_j} \quad (2.4)$$

Où σ_j est la variance de la j me variable

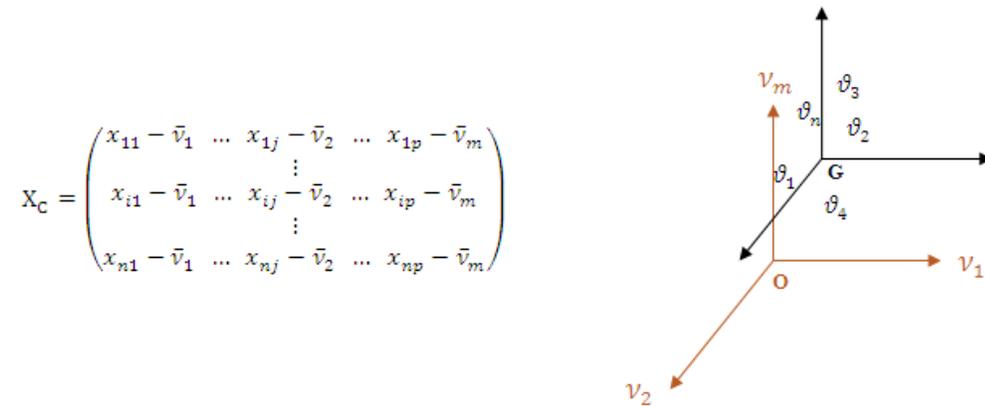


FIGURE 2.3 : Nuage centré sur le centre de gravité.

La matrice de variance-covariance :

$$\Sigma = \left(\frac{1}{n} X^T X \right) \in \mathfrak{R}^{m \times m} \quad (2.5)$$

Axes principaux et composantes principales :

Notons $P = \begin{pmatrix} P_1 & \dots & P_m \end{pmatrix} \in \mathfrak{R}^{m \times m}$ matrice de vecteurs propres et les λ_i sont les valeurs propres de la **matrice de variance-covariance** où la décomposition en valeurs singulières de cette matrice donne :

$$\Sigma = P \Lambda P^T \quad (2.6)$$

Où Λ est la matrice diagonale des valeurs propres dans l'ordre décroissant :

$$\Sigma = \begin{pmatrix} \lambda_1 & 0 & 0 & 0 \\ 0 & \lambda_2 & 0 & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \lambda_m \end{pmatrix}_{\lambda_1 > \lambda_2 > \dots > \lambda_m} \quad (2.7)$$

Les composantes principales sont les vecteurs de projections des observations (vecteurs de mesures) sur les axes de direction des vecteurs propres de la matrice

de corrélation de données, ces composantes sont obtenues par :

$$T = XP \quad (2.8)$$

$$T = \begin{bmatrix} T_1 & T_2 & \cdots & T_m \end{bmatrix} \in \mathfrak{R}^{n \times m}$$

Modèle ACP :

L'objectif est de diminuer la dimension de l'espace de représentation des observations, une fois déterminé le nombre $\ell < m$ de composantes à retenir (**la dimension réduite** à choisir), la matrice X peut être approximée et pour cela, la matrice P est partitionnée sous la forme :

$$P = \begin{pmatrix} \hat{P}_\ell & \tilde{P}_{m-\ell} \end{pmatrix}$$

- \hat{P}_ℓ : les ℓ premiers vecteurs propres constituent l'**espace principale EP**, \hat{S}
- $\tilde{P}_{m-\ell}$: les $(m - \ell)$ derniers vecteurs propres constituent l'**espace résiduel ER**, \tilde{S}

En ce sens, l'ACP détermine la transformation optimale suivante :

$$T = XP \Rightarrow \hat{T} = X\hat{P}$$

$$X = TP^T \Rightarrow \hat{X} = \hat{T}\hat{P}^T \Rightarrow \hat{X} = X\hat{P}\hat{P}^T \quad (2.9)$$

Notons que :

$$\hat{C} = \hat{P}\hat{P}^T \quad (2.10)$$

$$\left(I_m - \hat{C}\right) = \left(I_m - \hat{P}\hat{P}^T\right) = \tilde{C} \quad (2.11)$$

Avec

$$\hat{X} = X\hat{C} \quad (2.12)$$

et

$$\tilde{X} = X\tilde{C} \quad (2.13)$$

L'estimation de X par l'ACP est donnée par la formule suivante :

$$\hat{X} = \sum_{j=1}^{\ell} (T_j P_j^T)$$

Donc, les données restantes ou résiduelles de la matrice de données X représentent la perte de l'information acceptable de cette technique :

$$\tilde{X} = \sum_{j=\ell+1}^m (T_j P_j^T)$$

Où

$$X = \hat{X} + \tilde{X} \quad (2.14)$$

2.4 Choix de la dimension de l'espace réduit

Concernant le choix du nombre de composantes principales qui doit être retenu, il existe plusieurs critères tels que le *pourcentage cumulé de la variance totale (PCV)*, la *moyenne des valeurs propres*, la *validation croisée (PRESS)*, *variance de l'erreur de reconstruction (VER)*, et cette dernière approche avec la première représentent notre choix pour déterminer la dimension de l'espace principal dans cette étude :

2.4.1 Variance de l'erreur de reconstruction (VER) :

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 :

$$\hat{X} = X\hat{C} \quad \tilde{X} = X\tilde{C}$$

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

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

$$z_j = \frac{1}{1 - C_{jj}^T} \begin{bmatrix} C_{-j}^T & 0 & C_{+j}^T \end{bmatrix} x(k) \quad (2.15)$$

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

C_{+j}^T : les $(m - j)$ derniers éléments de la *jème* 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 *jème* variable est le suivant :

$$x(k) = \begin{bmatrix} x_1(k) & \cdots & x_{j-1}(k) & z_j(k) & x_{j+1}(k) & \cdots & x_m(k) \end{bmatrix}^T$$

Le but dans cette méthode est de minimiser la variance de l'erreur de reconstruction de la *jème* variable de $x(k)$:

$$\varepsilon = \xi_j^T [x(k) - x_j(k)] \quad (2.16)$$

$$\text{Où } \xi_j^T = \begin{bmatrix} 0 & \cdots & 1 & \cdots & 0 \end{bmatrix}^T$$

Le nombre de composantes principales à retenir s'obtient en minimisant par rapport à ℓ le critère 2.17, voir la figure 2.4.

$$VER(\ell) = \sum_{j=1}^m \frac{\sigma_j(\ell)}{\xi_j^T \sum \xi_j} \quad (2.17)$$

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

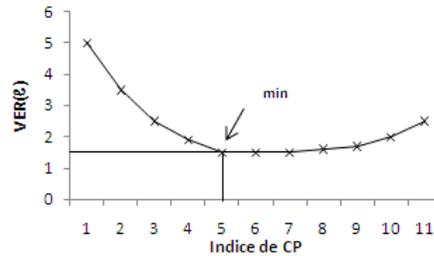


FIGURE 2.4 : Selection du nombre de CPs à retenir par le critère est VER.

2.4.2 Pourcentage cumulé de la variance (PCV) :

Ce critère est 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, voir la figure 2.5.

En général, on a :

$$PCV(\ell) = 100 \left(\frac{\sum_{j=1}^{\ell} \lambda_j}{\sum_{j=1}^m \lambda_j} \right) \% \quad (2.18)$$

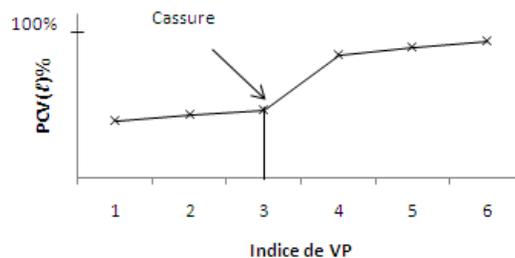


FIGURE 2.5 : Selection du nombre de CPs par PCV.

Dans ce cas, l'inflexion de la courbe entre la 3ème et la 4ème valeur propre, exprime la grande différence entre elles dans la concentration d'information.

La figure 2.6 résume les étapes de l'ACP linéaire.

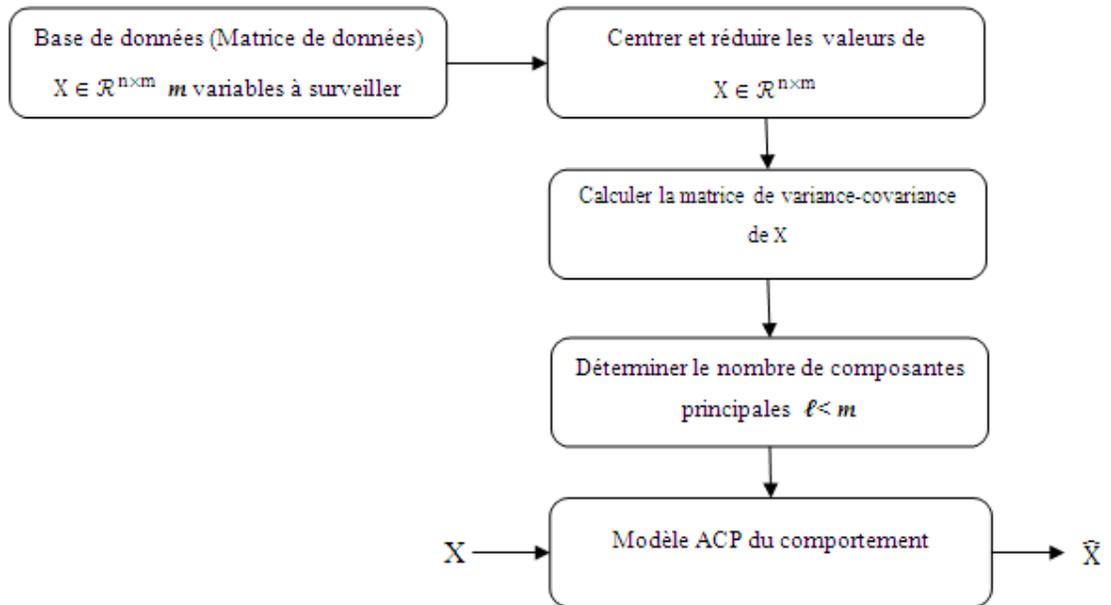


FIGURE 2.6 : Etapes pour la détermination d'un modèle ACP.

Une fois le modèle d'ACP est obtenu, il faut détecter et localiser les défauts qui peuvent apparaître dans le fonctionnement d'un processus, à l'aide du modèle ACP linéaire obtenu.

2.5 Détection par ACP Linéaire

La plus part des études récentes utilisent *l'erreur quadratique de prédiction* (Q), et *la statistique de Hotelling* (T^2), pour la détection des défauts de mesures, ces deux indicateurs donnent l'ordre sur l'apparition ou non d'un défaut :

2.5.1 Statistique de Hotelling (T^2) :

La statistique T^2 est calculée à partir des ℓ premières composantes principales :

$$T^2(k) = \hat{t}(k)\hat{\Lambda}^{-1}\hat{t}(k) = \sum_{a=1}^{\ell} \frac{t_a^2}{\lambda_a} \quad (2.19)$$

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

$$T^2(k) \geq T_{\text{lim}}^2(k)$$

Où $T_{\text{lim}}^2(k)$ est la limite du contrôle pour ce critère

L'expression mathématique du seuil pour le critère de *Hotelling* donnée par :

$$T_{\text{lim}}^2(k) = \frac{\ell(n+1)(n-1)}{n(n-\ell)} F_{\ell, (n-\ell), \alpha}^2 \quad (2.20)$$

T_{lim}^2 peut être approximée par F-distribution avec ℓ le degré de liberté et α le niveau de signification (représente le quantile de la distribution).

2.5.2 Statistique SPE (Q) :

Par contre à la première, cette statique est appliquée sur les dernières composantes principales :

$$SPE(k) = \tilde{t}^T(k) \tilde{t}(k) = \sum_{a=\ell+1}^m t_a^2 \quad (2.21)$$

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

$$SPE(k) \geq \delta^2$$

Où δ^2 est le seuil de confiance pour cet indicateur.

$$\delta_\alpha^2 = g\chi_{h,\alpha}^2 \quad (2.22)$$

$$g = \frac{\theta_2}{\theta_2} \quad (2.23)$$

$$h = \frac{\theta_1^2}{\theta_2} \quad (2.24)$$

$$\theta_i = \left(\sum_{j=\ell+1}^m \lambda_j^i \right)_{i=1,2} \quad (2.25)$$

δ^2 peut être approximée par χ^2 - *distribution* avec h le degré de liberté, α le niveau de signification et le coefficient g .

Afin de réduire les fausses alarmes, il est possible de filter la statistique SPE par un filtre EWMA (*Exponentially Weighted Moving Average*) :

$$\begin{aligned} \tilde{t}(k) &= (I - \beta)\tilde{t}(k-1) + \beta\tilde{t}(k) \\ \tilde{t}(0) &= 0 \end{aligned} \quad (2.26)$$

Où $\beta = \gamma I$ est une matrice diagonale dont les facteurs d'oubli pour les résidus où γ est le facteur d'oubli $0 < \gamma < 1$.

On obtient ainsi le SPE filtrés :

$$\overline{SPE}(k) = \tilde{t}^T(k) \tilde{t}(k) \quad (2.27)$$

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

$\overline{SPE}(k) > \bar{\delta}^2$ où $\bar{\delta}^2$ est le nouveau seuil de confiance pour cet indicateur filtré :

$$\bar{\delta}^2 = \frac{\gamma}{2 - \gamma} \delta^2 \quad (2.28)$$

2.6 Localisation par ACP linéaire

Plusieurs méthodes utilisent l'ACP ont été proposées pour localiser les variables en défaut :

2.6.1 Localisation par calcul de contribution :

La contribution au critère SPE :

$$cont_j^{SPE}(k) = [\tilde{x}_j(k)]^2 = [x_j(k) - \hat{x}_j(k)]^2 \quad (2.29)$$

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

La contribution au critère de Hotelling (T^2) :

$$T^2 = \tilde{t}^T \hat{\Lambda}^{-1} \tilde{t} = \sum_{a=1}^{\ell} \frac{t_a^2}{\lambda_a} \quad (2.30)$$

$$\lambda_a = S_a^2$$

Nous remarquons que la distance de Hotelling est la somme des carrés des CPs normalisées dont chaque CP ou score est exprimé comme suit :

$$t_a = p_a^T x = \sum_{j=1}^m p_{aj} x_j \quad (2.31)$$

p_{aj} est le jème élément du vecteur propre p_a correspondant à la valeur propre λ_a

La contribution de la jème variable x_j à une composante principale normalisée est :

$$cont_j^{(t_a/s_a)^2} = \frac{t_a}{\lambda_a} p_{aj} x_j \quad (2.32)$$

Cela prouve que la contribution totale de la variable x_j dans le calcul de toutes les composantes principales normalisées est :

$$cont_j^{T^2} = \sum_{a=1}^{\ell} cont_j^{(t_a/s_a)^2} \quad (2.33)$$

2.6.2 Indice de validité des capteurs (SVI) :

Après la détection de la présence d'un défaut, on effectue la reconstruction de toutes les variables à partir de l'instant de détection, et on calcule l'indice de détection. Par exemple, si on détecte un défaut à l'instant de temps k , $SPE_j(k)$ représente l'indice de détection de la jme variable reconstruite.

La localisation est effectuée par **comparaison de l'indice de détection avant et après la reconstruction**, ce qui permet de calculer le rapport qu'on appelle **indice de validité** $\eta_j(k)$ où :

$$\eta_j(k) = \frac{SPE_j(k)}{SPE(k)} \quad (2.34)$$

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

CHAPITRE 3

MODÈLE NEURONAL ÉPARSE AUTO-ENCODEUR

3.1 Introduction

De nos jours, les systèmes technologiques, qui sont devenus de plus en plus complexes, doivent accomplir les tâches pour lesquelles ils sont conçus en toute sécurité tout en respectant l'environnement. L'analyse de données permet de détecter les nouveautés et les événements anormaux par l'extraction de relations utiles à partir de l'historique, en construisant des statistiques. En ce sens, les statistiques univariées ont été l'origine de nombreuses techniques utilisées en maîtrise (contrôle) statistique de processus. En effet, les cartes de contrôle (control charts) sont les outils de base pour appliquer le contrôle statistique de processus. Ceci permet de visualiser l'évolution de processus pouvant identifier les changements qui affectent ses performances. Par ailleurs, les dimensions des processus et l'existence de colinéarités entre variables peuvent limiter l'efficacité en terme d'erreur d'identification par une interprétation directe de ces cartes (charts).

Dans ce contexte, la réduction de l'espace des variables par des **méthodes de projection en sous espace** permet de révéler l'information utile, la méthode la plus répandue est l'Analyse en Composantes Principales (ACP) [1]. Elle permet de faciliter le contrôle statistique de processus en projetant les données à un sous-espace de dimension réduite capable de caractériser l'état du processus.

Néanmoins, l'ACP est une méthode linéaire et n'est pas bien adaptée aux situations de variables non linéaires ; souvent rencontrées dans les procédés complexes ou de grandes dimensions. Récemment, l'apprentissage profond (deep learning), qui représente une nouvelle branche de l'intelligence artificielle, a été appliqué avec succès dans de nombreux domaines. Il est capable de former des représentations cachées par des architectures profondes (deep architectures), ce qui permet de mieux appréhender la prédiction et la classification [2] [3].

Dans le cadre de notre projet, nous allons étudier le réseau de neurones épars autoencodeur (stacked sparse autoencoder, SSAE) [4], [5], [6] comme un outil de contrôle statistique de processus afin de détecter les nouveautés (Novelty detection) et éventuellement la validation et la reconstruction des données de capteurs. Ce réseau consiste de trois couches, une couche d'entrée, une couche de sortie et une autre cachée utilisant des contraintes éparses (sparse constraints) dans la couche cachée d'étranglement (bottleneck layer) pour reconstruire les données d'entrée. En principe, la reconstruction de données peut être utilisée pour détecter et isoler les capteurs défaillants par la méthode de redondance analytique (analytical redundancy) qui permet de détecter toute déviation entre les mesures et la reconstruction (discrepancy between the measurements and the reconstructed data). En fait, après la reconstruction et étant donnée un ensemble de variables mesurées, le recours à la détection de nouveautés permet de décider quant à la nature d'une nouvelle donnée (mode normal ou événement anormal), ce qui justifie son utilité pour la détection et la localisation de défauts.

Parmi les méthodes de détection existantes, la statistique- Q et la statistique de Hotelling T^2 sont les plus utilisées [7]. Il y a également la limite de confiance non paramétrique dérivée à partir des estimateurs de densités à noyaux (kernel density estimate, KDE). Après la détection d'un événement anormal, l'étape suivante consiste à identifier la cause ou le capteur défaillant. Dans ce cas, il est possible d'utiliser la méthode de contribution (contribution plots) ou encore le principe de reconstruction (reconstruction principle).

Dans notre étude, on s'intéresse au réseau épars autoencodeur (Stacked Sparse Autoencoder, SSAE). Ce réseau est utilisé pour modéliser la distribution ou les processus ayant généré les données, ce qui permet de reconstruire les entrées.

Ce chapitre est organisée comme suit : La section 3.2 décrit le réseau SSAE. La section 3.3 présente la statistique- Q , appelée aussi SPE (Square Prediction Error) et comment définir les limites de confiance. Ensuite, la section 3.4 décrit les méthodes d'identification de défauts, en accordant un intérêt particulier à celle basée sur le principe de reconstruction et au concept d'**indice de validité de capteur** (Sensor Validity Index, SVI).

3.2 Le modèle neuronal éparsé autoencodeur (SSAE)

L'apprentissage profond (deep learning) fait partie de l'apprentissage automatique (machine learning) qui tente d'apprendre des abstractions de haut niveau en utilisant des architectures hiérarchiques. Avec l'amélioration des moyens de calcul, de stockage et de l'internet, de nouvelles base de données sont devenues disponibles, et aujourd'hui on parle de "big data". L'apprentissage profond a permis d'avoir des performances extra-ordinaires pour une panoplie d'applications. Ainsi, il a été appliqué avec succès dans le traitement d'image et l'analyse visuelle, mais son application dans le domaine de contrôle de processus n'est qu'au début.

Les modèles deep learning sont utilisés comme outils d'extraction de paramètres en utilisant des couches cachées ou d'étranglement dans un apprentissage non supervisé.

Dans un apprentissage supervisé, le réseau SAAE est composé d'une couche d'entrée, couche cachée, et une couche de sortie. Il tente de rendre le vecteur de sortie approxime le vecteur d'entrée par codage-décodage (learning an encoder and a decoder).

Dans un premier temps, le vecteur d'entrée $X_i = \{1, 2, 3, \dots, N\}$ est transformé à la partie cachée par la fonction h_i , comme suit :

$$h_i = f(x_i) = \text{sigm}(W_1x + b_1) \quad (3.1)$$

où W_1 et b_1 représentent respectivement, le poids (weight) et l'offset (bias) entre la couche d'entrée et la partie cachée, $\text{sigm}(x)$ est la fonction sigmoïde (sigmoid function).

Dans la couche de décodage, h_i est transformé à la sortie dénotée par \hat{x} . Avec la fonction d'activation :

$$\hat{x}_i = g(h_i) = \text{sigm}(W_2h + b_2) \quad (3.2)$$

où W_2 et b_2 sont le poids et l'offset entre la couche cachée et celle de sortie (\hat{x}).

Le réseau d'étranglement (bottleneck network) dont la fonction d'erreur ou d'apprentissage évoque une pénalité éparsé (sparsity penalty) dans la couche d'étran-

lement est appelé réseau de neurone éparsé autoencodeur (Stacked Sparse Autoencoder, SSAE). Ce réseau consiste à prédire sa sortie pour estimer l'entrée, ceci en optimisant la fonction cout (cost function) définie par :

$$J = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|\hat{x}_i - x_i\|^2 \right) + \frac{\lambda}{2} \sum_{i=1}^N \|W_i\|^2 + \beta \sum_{j=1}^m KL(\rho \| \hat{\rho}_j) \quad (3.3)$$

où m est nombre de neurones cachés. λ et β qui déterminent la pénalité (the weight decay and the sparsity penalty terms).

Dans l'équation (3.3), le premier terme représente l'erreur de reconstruction, le second terme est de régularisation et le dernier de sparsité (Sparsity Penalty term), où $KL(\rho \| \hat{\rho}_i)$ est la mesure de divergence de Kullback-Leibler, elle est utilisée pour calculer la différence entre ρ et $\hat{\rho}_i$ qui est sous contrainte pendant l'apprentissage. $KL(\rho \| \hat{\rho}_i)$ est définie par [8] :

$$KL(\rho \| \hat{\rho}_i) = \rho \log \frac{\rho}{\hat{\rho}_i} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (3.4)$$

L'algorithme de rétro-propagation (back propagation algorithm) est utilisé pour minimiser la fonction cout et pour trouver les paramètres du réseau W_1 , W_2 , b_1 , b_2 .

3.3 Détection d'anomalie (Anomaly detection)

Il y a plusieurs techniques pour détecter les défauts [9]. La mesure la plus utilisée est la statistique-Q, connue sous SPE (squared prediction error) :

$$Q = SPE = \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (3.5)$$

où N est le nombre d'échantillons.

3.3.1 Limites de confiance ou de contrôle

3.3.1.1 Distribution paramétrique χ^2 (δ_α^2)

La limite de contrôle indique lorsque le processus devienne non maîtrisable (out of control), c-à-d que les données ne ressemble plus à celles du mode normal pour lequel $SPE \leq \delta_\alpha^2$. Par ailleurs, si $SPE > \delta_\alpha^2$, le système est en mode anormal, probablement avec la présence d'un défaut, où δ_α^2 est spécifié pour la limite de contrôle pour le SPE [10], qui est calculée pour la distribution chi^2 par :

$$\begin{aligned}\delta &= g\chi_{h,\alpha}^2 \\ g &= \frac{v}{2m} \\ h &= \frac{2m^2}{v}\end{aligned}\tag{3.6}$$

où m et v sont respectivement la **moyenne** et **l'écart type** du SPE.

3.3.1.2 Estimateur à noyaux (Kernel Density Estimation, KDE)

L'estimateur à noyaux KDE (Kernel density estimation) est un **estimateur non paramétrique** des fonction de densité de probabilités de variables aléatoires pour n'importe quel point du support. Etant donnée une matrice d'échantillons de n variables et m échantillons, le KDE de la fonction de densité $f(x)$ au point x est défini comme suit :

$$f(x) = \frac{1}{mh} \sum_{j=1}^n K\left(\frac{x - x_j}{h}\right)\tag{3.7}$$

Où h est le paramètre de lissage (bandwidth parameter) et K est la fonction noyau (Kernel function).

3.4 Identification de défaut

3.4.1 Courbes de contribution (Contribution Plots)

Après la détection de défaut, il est nécessaire d'identifier le capteur défaillant en utilisant les courbes de contribution [11].

La contribution de la variable j à la statistique Q est calculée comme suit :

$$C_{ijk}^Q = e_{ijk}^2 \quad (3.8)$$

Où $e = (x_i - \hat{x}_i)$.

3.4.2 Principe de Reconstruction Nonlinear

Afin de reconstruire la donnée erronée, il est nécessaire d'éliminer son influence (figure 3.1). En ce sens, l'approche consiste à prédire la mesure \hat{x}_j du processus, en

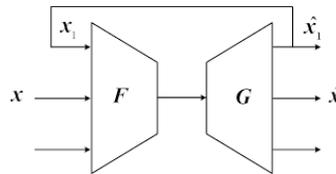


FIGURE 3.1 : Principe de Reconstruction

la remplaçant par la j^{me} variable du processus d'une manière itérative jusqu'à la convergence de l'algorithme comme suit :

$$\tilde{x}_i = \xi_j^T G(F(x_j)) \quad (3.9)$$

où $\tilde{x}_i = (x_1, x_2, \dots, \hat{x}_j, \dots, x_m)$, ξ_j^T est la j^{ime} colonne de la matrice identité. Répéter pour l'itération i :

$$\hat{x}^{(i)} = G(F(\tilde{x})) \quad (3.10)$$

qui va converger pour :

$$\left\| \hat{x}_j^{(i+1)} - \hat{x}_j^{(i)} \right\| < \varepsilon \quad (3.11)$$

où ε est un seuil de convergence.

3.4.3 Indice de validité de capteur

L'indice de validité de capteur SVI (Sensor Validity Index) est une autre technique pour identifier un défaut. C'est une mesure introduite pour la première fois dans le cas de l'ACP linéaire par [12], elle est définie par :

$$\eta_j^2(k) = \frac{SPE_j(k)}{SPE(k)} \quad (3.12)$$

où SPE est l'erreur de prédiction globale (quadratic global prediction error) **calculée avant la reconstruction** et SPE_j est la j th SPE **calculée après reconstruction** [13]. **L'indice de validity d'un capteur en défaut tend vers zéro.**

CHAPITRE 4

RÉSULTATS ET DISCUSSIONS

4.1 Introduction

De nos jours, les systèmes technologiques, qui sont devenus de plus en plus complexes, doivent accomplir les tâches pour lesquelles ils sont conçus en toute sécurité tout en respectant l'environnement. L'analyse de données permet de détecter les nouveautés et les événements anormaux par l'extraction de relations utiles à partir de l'historique, en construisant des statistiques. En ce sens, les statistiques univariées ont été l'origine de nombreuses techniques utilisées en maîtrise (contrôle) statistique de processus. En effet, les cartes de contrôle (control charts) sont les outils de base pour appliquer le contrôle statistique de processus. Ceci permet de visualiser l'évolution de processus pouvant identifier les changements qui affectent ses performances. Par ailleurs, les dimensions des processus et l'existence de colinéarités entre variables peuvent limiter l'efficacité en terme d'erreur d'identification par une interprétation directe de ces cartes (charts).

Afin de montrer la validité et les performances du réseau de neurones épars autoencodeur (Stacked Sparse Autoencoder, SSAE) pour le contrôle statistique des processus non linéaires et peuvent être multi-modes, nous avons choisi un exemple de simulation et un procédé réel de traitement de l'eau potable.

4.2 Cas d'études

4.2.1 Système de simulation

Comme premier exemple, nous avons choisi de simuler un système non linéaire relativement simple à trois variables [14], dans lequel t est distribué uniformément dans l'intervalle $[-1, 1]$; ε_i désigne un bruit blanc gaussien (Gaussian white noise) de moyenne nulle et d'écart type 0.01 pour générer $N = 1000$ échantillons (points)

qui vont servir à l'apprentissage d'un modèle SSAE.

$$\begin{aligned}x_1 &= t^2 + 0.3 \sin(2\pi t) + \varepsilon_1 \\x_2 &= t + \varepsilon_2 \\x_3 &= t^3 + t + 1 + \varepsilon_3\end{aligned}\tag{4.1}$$

Après la création du modèle (l'erreur d'apprentissage devient très petite), il est possible de l'appliquer dans la surveillance du processus pour de nouvelles données. Dans un premier, il faut l'appliquer juste sur les données du mode normal pour calculer la limite de confiance du SPE. Ensuite, pour un nouveau vecteur d'entrée (nouvelle donnée) à instant k , il faut comparer le $SPE(k)$ avec sa limite de confiance. La figure 4.1 montre le SPE pour 250 points du mode normal (sous contrôle). Ensuite, nous avons introduit un défaut pour voir l'évolution du SPE qui

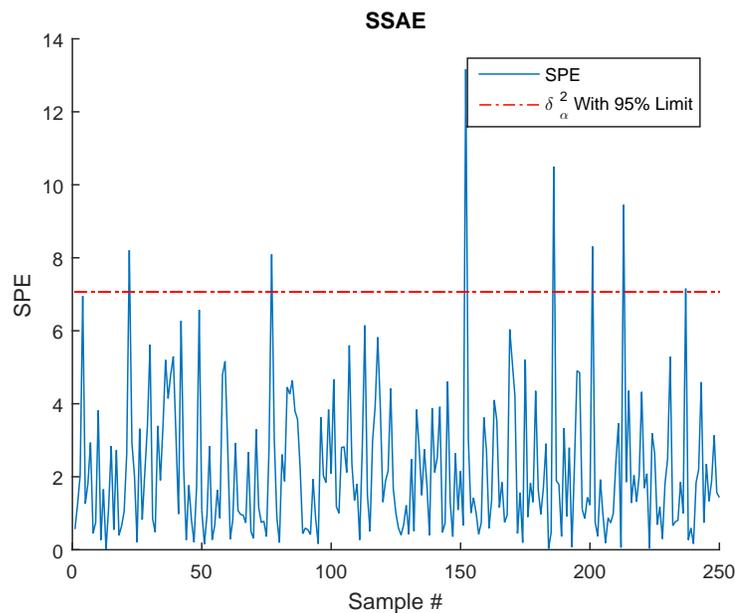


FIGURE 4.1 : SPE : données du mode normal.

va dépasser son seuil de contrôle, comme le montre la figure ??e simulate a fault in one of the sensors and we notice the evolution of SPE with the two thresholds as it is illustrated in figure 4.2. En examinant les figure, on peut affirmer que le modèle

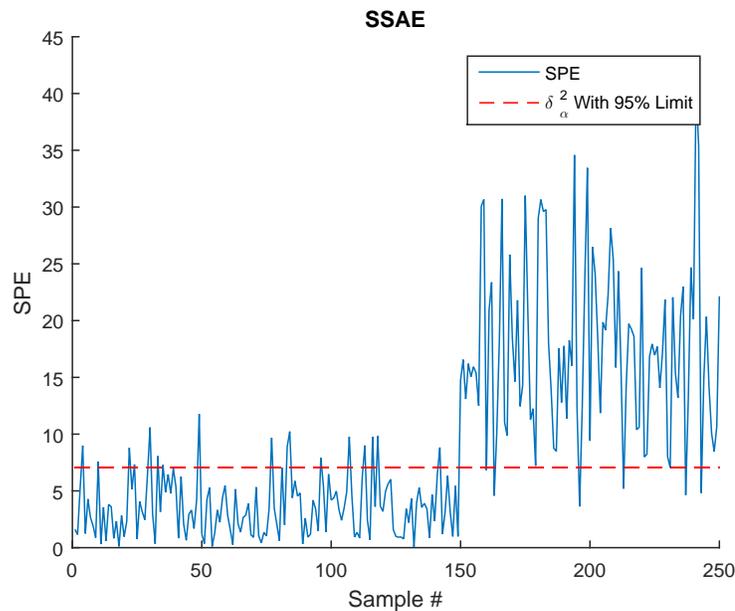


FIGURE 4.2 : SPE : données avec un défaut de capteur

SSAE est capable de détecter le défaut à partir de l'échantillon 150. Par ailleurs, il est possible d'identifier le défaut soit en utilisant la méthode contribution ou le principe de reconstruction, come le montre la figure 4.3 et la figure 4.4 où le défaut est injecté sur le capteur 3. L'autre méthode de localisation du capteur défaillant est le SVI, comme le montre la figure 4.5.

4.2.2 Application sur un procédé de traitement de l'eau potable

Dans un procédé typique d'alimentation et de traitement de l'eau potable, l'eau brute est pompée de la source (barragare ou lac) par des stations de pompages à l'usine pour être filtrée et désinfectée.

Le type de traitement dépend de la qualité de l'eau de source. En général, une eau de qualité réduite engendre des coûts de traitement.

Un procédé de traitement consiste d'un ensemble de processus physico-chimiques, et il est connu que si un problème effecte un processus, il va affecter les autres. D'habitude, le traitement de l'eau de surface est composé de quatre processus :

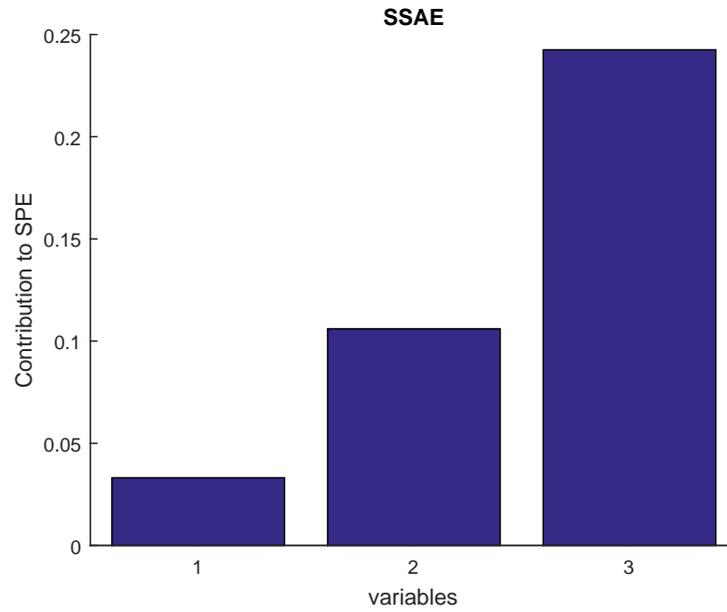


FIGURE 4.3 : Isolation de défaut en utilisant la méthode de contribution (normalized contribution plots) pour un défaut dans le capteur 3

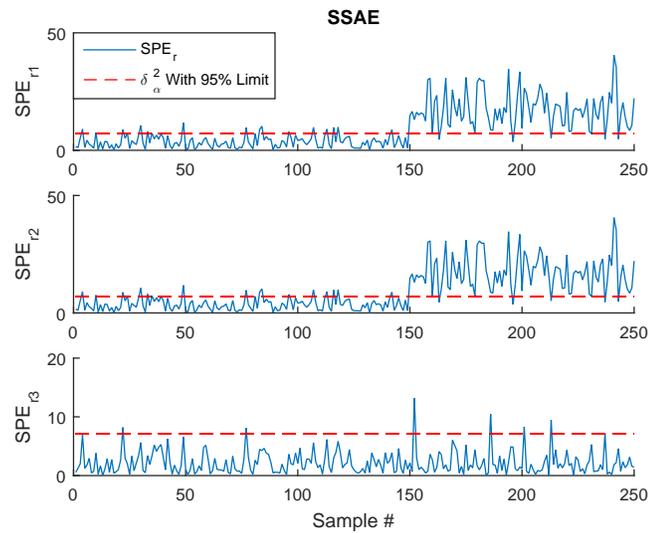


FIGURE 4.4 : Isolation de défaut en utilisant la méthode de contribution (normalized contribution plots) pour un défaut dans le capteur 3

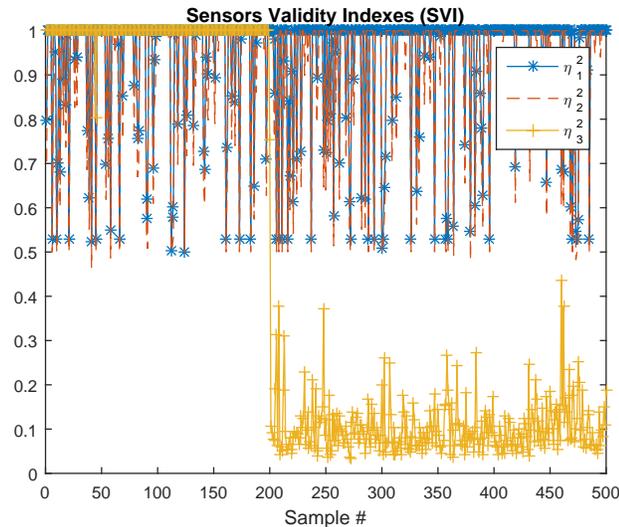


FIGURE 4.5 : Identification de défaut en utilisant l'indice de validité de capteur (Sensor Validity Index, SVI) pour un défaut dans le capteur 3.

floculation, sédimentation, filtration et désinfection, comme le montre la figure 4.6. L'ajout de produits chimiques est l'étape la plus importante pour le traitement de l'eau de surface. Il s'agit principalement de **coagulation**, qui consiste à ajouter l'aluminium (aluminum or iron salts) pour produire des floes de particules colloïdale et des dépôts de contaminants.

Pour le moment, la plupart des stations déterminent le **dosage optimal de coagulant** en utilisant la technique "jar test" qui consiste à effectuer des analyses physico-chimiques de laboratoire.

Afin d'améliorer la qualité de traitement de l'eau potable tout en réduisant les coûts, il y a une tendance pour utiliser des techniques modernes basées sur des algorithmes d'optimisation et d'analyse de séries temporelles.

Dans ce contexte, l'algorithme du système automatique de dosage optimal de coagulant utilise les paramètres de qualité de l'eau brute comme entrée, et délivre en sortie une commande à la pompe doseuse.

Le procédé étudié est celui de Oued El-Othmania, près de Constantine, situé dans le

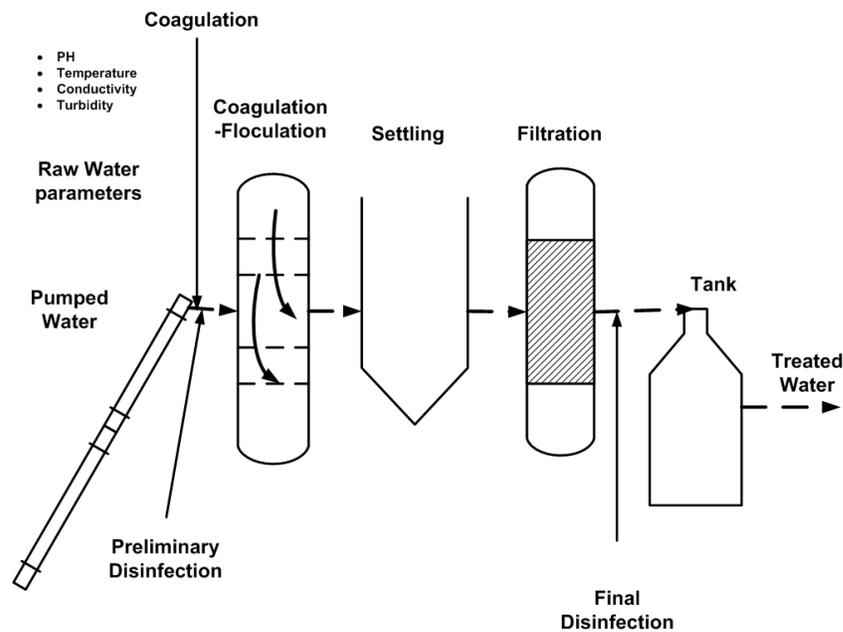


FIGURE 4.6 : Les unités de traitement de l'eau potable.

nord-est de l'Algérie [15]. Le jeu de données est composée des paramètres de l'eau brute ainsi que de l'eau traitée : Turbidité, Température, PH et O_2 , ce qui donne 8 variables. Ces données sont obtenues à partir du système SCADA couvrant une période de 365 jours (une année). Ces données ont été utilisées pour faire l'apprentissage et le test du modèle neuronal. La figure 4.7 donne la statistique SPE qui montre que le processus est sous contrôle. Ensuite, on ajoute un défaut d'offset à partir de l'échantillon 120 sur le capteur 8 qui représente le capteur de l'oxygène O_2 de l'eau traité. La statistique SPE est montré sur la figure 4.8. L'identification du capteur en défaut est indiquée sur la figure 4.9 en utilisant la contribution (normalized contribution plots), et pour l'indice de validié de capteur (SVI) en figure 4.10. En conclusion , on peut affirmer que les résultats reportés sur un exemple de simulation et sur des données réelles d'un procédé de traitement de l'eau potable montrent l'efficacité de cette approche. Il a été montré que ce projet à un impact socio-économique. En perspectives, nous souhaitons que ce travail trouvera une continuité logique en l'appliquant sur site pour améliorer les performances des procédés de traitement et d'alimentation en eau potable.

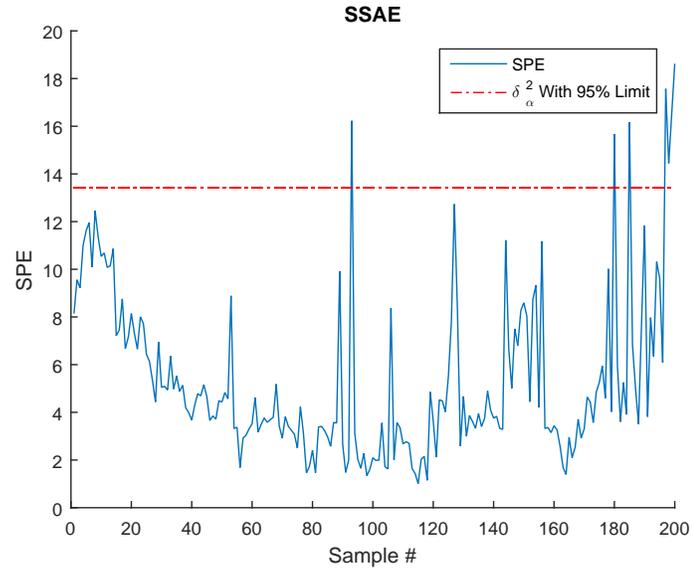


FIGURE 4.7 : SPE : Donnée de la condition normale

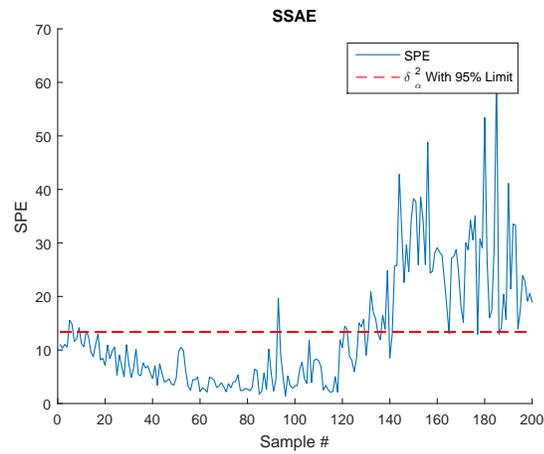


FIGURE 4.8 : SPE : Cas de condition anormale

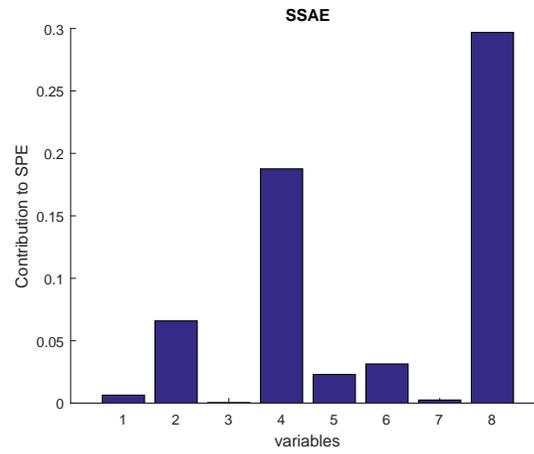


FIGURE 4.9 : Identification de défaut par contribution (normalized contribution plots) pour le modèle neuronal SSAE

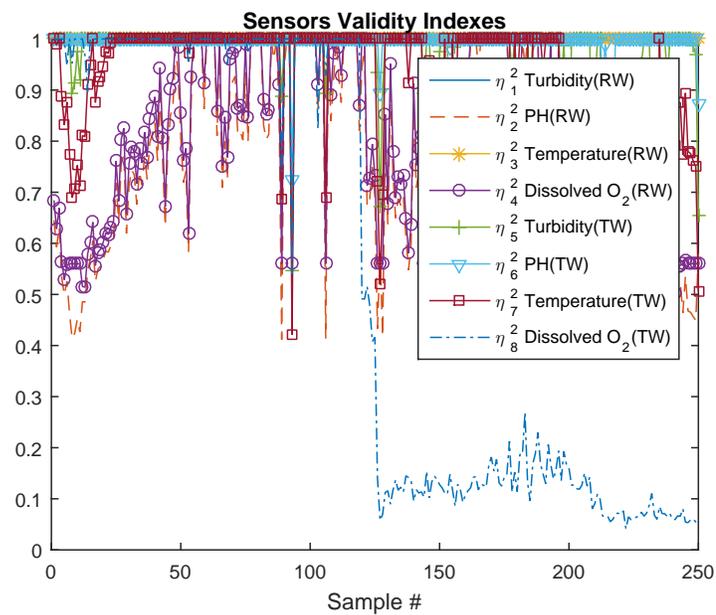


FIGURE 4.10 : Les indices de validité des capteurs (sensor validity indexe, SVI) des capteurs de l'eau brute et traitée en utilisant le modèle neuronal éparsé, SSAE

CONCLUSION

Avec la complexité des systèmes technologiques où les pannes peuvent provoquer des dégâts et des pertes économiques considérables, il devient primordial de mettre en œuvre des systèmes de surveillance et de diagnostic afin d'éviter les arrêts inattendus, et garantir une grande disponibilité des équipements tout en respectant l'environnement.

Nous avons présenté les techniques de diagnostic des systèmes qui dépendent d'une représentation du système, qui peut être physique, à base de règles relationnelles, ou encore à base d'historique. Un intérêt particulier a été accordé à l'analyse de données et l'apprentissage automatique. Dans ce contexte, l'ACP est l'une des méthodes de contrôle statistique multivarié les plus utilisées, et comme elle est linéaire dont le principe est simple mais son application est limitée au cas de corrélation linéaire entre les variables.

Nous avons montré que le réseau de neurones épars autoencodeur (Stacked Sparse Autoencoder, SSAE), qui est composé de trois couches, peut être utilisé avec succès pour reconstruire les données issues de procédés non-linéaires et multimodes, c-à-d qui ne peuvent pas être modélisées par la loi de probabilité de Gauss (Non Gaussian Processes). La détection d'événement anormal s'effectue si la statistique SPE dépasse son seuil de confiance. Ensuite, l'identification du capteur défaillant repose sur le principe de reconstruction en utilisant le concept de validité de capteur (Sensor Validity index) ou tout simplement sur les courbes de contribution à l'erreur qui dépasse sa limite de confiance.

Les résultats reportés pour un système simulé et pour des données réelles d'un procédé de traitement de l'eau potable montrent l'efficacité de cette approche. Il est clair que ce projet a un impact socio-économique. En perspectives, nous souhaitons que ce travail trouvera une continuité logique en l'appliquant sur site pour améliorer les performances des procédés de traitement et d'alimentation en eau potable.

BIBLIOGRAPHIE

- [1] I. T. Jolliffe and J. Cadima, “Principal component analysis : a review and recent developments,” *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2065, p. 20150202, mar 2016.
- [2] G. E. Hinton and R. R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *science*, vol. 313, no. 5786, pp. 504–507, 2006.
- [3] R. Collobert and J. Weston, “A unified architecture for natural language processing : Deep neural networks with multitask learning,” in *Proceedings of the 25th international conference on Machine learning*. ACM, 2008, pp. 160–167.
- [4] S. Lu, H. Liu, and C. Li, “Manifold regularized stacked autoencoder for feature learning,” in *2015 IEEE International Conference on Systems, Man, and Cybernetics*. IEEE, oct 2015.
- [5] J. Xu, L. Xiang, Q. Liu, H. Gilmore, J. Wu, J. Tang, and A. Madabhushi, “Stacked sparse autoencoder (SSAE) for nuclei detection on breast cancer histopathology images,” *IEEE Transactions on Medical Imaging*, vol. 35, no. 1, pp. 119–130, jan 2016.
- [6] F. Lv, X. Fan, C. Wen, and Z. Bao, “Stacked sparse auto encoder network based multimode process monitoring,” in *2018 International Conference on Control, Automation and Information Sciences (ICCAIS)*. IEEE, oct 2018.
- [7] D. White, B. Goodlin, A. Gower, D. Boning, H. Chen, H. Sawin, and T. Dalton, “Low open-area endpoint detection using a PCA-based $t/\sqrt{2}$ statistic and q statistic on optical emission spectroscopy measurements,” *IEEE Transactions on Semiconductor Manufacturing*, vol. 13, no. 2, pp. 193–207, may 2000.
- [8] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol, “Stacked denoising autoencoders : Learning useful representations in a deep network with a local denoising criterion,” *Journal of machine learning research*, vol. 11, no. Dec, pp. 3371–3408, 2010.

- [9] S. J. Qin, "Statistical process monitoring : basics and beyond," *Journal of Chemometrics*, vol. 17, no. 8-9, pp. 480–502, 2003.
- [10] P. Nomikos and J. F. MacGregor, "Multivariate spc charts for monitoring batch processes," *Technometrics*, vol. 37, no. 1, pp. 41–59, 1995.
- [11] J. A. Westerhuis, S. P. Gurden, and A. K. Smilde, "Generalized contribution plots in multivariate statistical process monitoring," *Chemometrics and Intelligent Laboratory Systems*, vol. 51, no. 1, pp. 95–114, may 2000.
- [12] R. Dunia, S. J. Qin, T. F. Edgar, and T. J. McAvoy, "Use of principal component analysis for sensor fault identification," *Computers & Chemical Engineering*, vol. 20, pp. S713–S718, jan 1996.
- [13] K. Bouzenad, M. Ramdani, N. Zermi, and K. Mendaci, "Use of NLPCA for sensors fault detection and localization applied at WTP," in *2013 World Congress on Computer and Information Technology (WCCIT)*. IEEE, jun 2013.
- [14] X. Zhang and Y. Li, "Multiway principal polynomial analysis for semiconductor manufacturing process fault detection," *Chemometrics and Intelligent Laboratory Systems*, vol. 181, pp. 29–35, oct 2018.
- [15] K. Mendaci, M. Ramdani, and T. Benzaraa, "Nonlinear multivariate statistical process monitoring of a water treatment plant," in *2013 5th International Conference on Modeling, Simulation and Applied Optimization (ICMSAO)*. IEEE, apr 2013.