

Nouvelles composantes informatives pour le diagnostic de fautes des procédés industriels par classification supervisée

Sylvain VERRON, Teodor TIPLICA, Abdessamad KOBİ

LASQUO/ISTIA,

62, Avenue Notre Dame du Lac. 49000 Angers, France.

sylvain.verron@univ-angers.fr, teodor.tiplica@univ-angers.fr, abdessamad.kobi@univ-angers.fr

Résumé— Cet article présente une méthode pour le diagnostic des procédés industriels. Nous sommes intéressés par le diagnostic de fautes perçue comme une classification supervisée. L'intérêt de la méthode proposée est de prendre en compte de nouvelles composantes (et donc de nouvelles informations) dans le classifieur. Ces nouvelles composantes sont des probabilités extraites d'un réseau Bayésien comparant les données de fautes aux données normales de fonctionnement. Les performances de cette méthode sont évaluées sur les données d'un problème benchmark : le Tennessee Eastman Process. Trois types de fautes sont prises en compte sur ce procédé complexe. Nous montrons sur cet exemple que l'addition de ces nouvelles composantes permet de faire décroître le taux de mauvaises classifications.

Mots-clés— Diagnostic de fautes, classification supervisée, réseau Bayésien.

I. INTRODUCTION

De nos jours les procédés industriels sont de plus en plus complexes. Ils intègrent beaucoup de capteurs fournissant des mesures sur certains attributs du système. Une étude de ces mesures peut permettre de décider de l'état de fonctionnement du procédé. Si le procédé n'est pas dans des conditions normales de fonctionnement, cela signifie qu'une faute est apparue. La détection et le diagnostic de fautes (Fault Detection and Diagnosis (FDD)) sont des champs de recherches très importants [1]. Le but de la FDD est de détecter, le plus tôt possible, l'apparition d'une faute dans le procédé. Une fois la fautes détectée, l'étape importante est le diagnostic. Le diagnostic est la décision sur la nature de la faute apparue dans le procédé, quelles sont les caractéristiques de cette faute, quelles sont les causes racines de cette faute.

On peut distinguer trois principales approches de méthodes pour la FDD [2] : l'approche basée sur des connaissances, l'approche basée sur un modèle et l'approche basée sur les données. Les approches basées sur l'exploitation des connaissances comprennent des méthodes bâties sur des modèles qualitatifs (AMDEC - Analyse des Modes de Défaillances, de leurs Effets et de leur Criticité ; Arbres de fautes ; Analyses des Risques) [3], [4]. Pour les méthodes basées sur un modèle, un modèle analytique du procédé est construit sur la base des relations physiques gouvernant le procédé [5]. Le modèle donne les valeurs normales de chaque capteurs (ou variables) du système à chaque instant d'échantillonnage, alors des résidus sont générées (les résidus sont les différences entre les mesures et les valeurs références estimées par le modèle en

conditions normales). Si le système est en fonctionnement normal, alors les résidus sont quasi nulles. Ainsi, leurs évaluations permettent de détecter et de diagnostiquer une faute. Théoriquement, les meilleures méthodes de FDD sont celles basées sur un modèle. Mais, l'inconvénient majeur de cette famille de techniques est le fait qu'un modèle détaillé du procédé est requis afin de le surveiller efficacement. Or, obtenir un modèle détaillé efficace peut être très difficile et coûteux en temps, et ce particulièrement pour des systèmes à grande échelle possédant beaucoup de variables. La dernière catégorie de méthodes pour la FDD sont les méthodes basées sur un historique du procédé. Ces techniques sont basées sur des développements statistiques rigoureux des données issues du procédé [6].

Dans la littérature, on peut trouver beaucoup de techniques basées sur l'exploitation des données pour la FDD. Concernant la détection, on peut notamment citer : la maîtrise statistique des procédés univariés [7], la maîtrise statistique des procédés multivariés [8], des techniques basées sur l'Analyse en Composantes Principales (ACP) [9]. Kano et al. [10] ont réalisé des comparaisons entre ces différentes techniques. Concernant les techniques de diagnostic, nous pouvons citer le livre de Chiang et al. [2] qui présente bon nombre d'entre elles (techniques basées sur l'ACP, analyse discriminante de Fisher, techniques basées sur la régression, etc).

L'objet de cet article est de présenter une nouvelle contribution pour le diagnostic de faute de système industriel. Classiquement, lorsque la classification supervisée est utilisée pour le diagnostic de fautes, on doit sélectionner les variables les plus informatives afin de faire décroître le taux de mauvaise classification. En effet, la suppression de variables portant peu d'informations permet d'accroître la robustesse du classifieur et d'accroître ainsi ses performances en classification. Dans cet article, nous proposons une solution alternative qui rajoute de nouvelles composantes donnant de nouvelles informations pour la classification. Ces nouvelles variables et donc ces nouvelles informations sont extraites à partir d'une comparaison des fautes aux conditions normales de fonctionnement.

L'article est structuré de la manière suivante. Dans la section II, nous introduisons la méthode de diagnostic de fautes par classification supervisée et présentons quelques classifieurs classiques. La section III présente notre contribution permettant de comparer une faute aux conditions normales de fonctionnement et d'obtenir ainsi de nouvelles

informations pour la classification de la faute. La section IV présente une évaluation de la méthode proposée sur le problème du Tennessee Eastman Process. Finalement, nous concluons sur cette méthode et présentons quelques perspectives dans la section V.

II. DIAGNOSTIC DE FAUTES PAR CLASSIFICATION SUPERVISÉE

A. Diagnostic de faute en tant que classification

Dès qu'un problème (une faute) a été détectée dans l'évolution d'un procédé au moyen d'une méthode de détection, nous devons identifier la classe d'appartenance de cette faute. Pour cela, le problème de diagnostic peut être vu comme la tâche de classifier correctement l'observation fautive dans une des classes de fautes prédéfinies. La tâche de classification nécessite la construction d'un classifieur (une fonction allouant une classe aux observations décrites par les variables du système). Deux types de classification existent : la classification non supervisée dont l'objectif est d'identifier le nombre et la composition de chaque classe présente dans les données ; la classification supervisée où le nombre de classes et la classe d'appartenance de chaque observation est connue dans un ensemble d'apprentissage, et dont l'objectif est de classer de nouvelles observations dans l'une des classes existantes. Par exemple, étant donné un ensemble d'apprentissage pour un système bivarié avec trois différentes fautes connues comme illustré sur la figure 1, nous pouvons facilement utiliser la classification supervisée afin de classifier une nouvelle observation fautive. Une sélection de composantes peut être utilisée afin de sélectionner seulement les variables les plus informatives du problème.




Fig. 1. Système bivarié à 3 fautes connus

B. Classifieur supervisé usuel

Nous avons vu comment diagnostiquer une faute à l'aide de classifieurs supervisés, nous présentons ici quelques classifieurs classiques. En effet, il n'y a pas de classifieur surpassant tous les autres, cela dépend de l'application.

B.1 Analyse Discriminante Linéaire

L'Analyse Discriminante Linéaire (ADL) est une technique de base pour la classification supervisée [11]. C'est un classifieur statistique. En effet la règle de classification est d'attribuer à une nouvelle observation la classe

possédant la plus grande probabilité conditionnelle. Afin de travailler avec les probabilités, une hypothèse classique est que les données suivent une densité Gaussienne. Dans ce cas, l'ADL attribue à une nouvelle observation \mathbf{x} la classe C_i possédant le coût minimal calculé par l'équation suivante :

$$\mathbf{x} \in C_i, \text{ si } i = \underset{i=1, \dots, k}{\operatorname{argmin}} \{K_i(\mathbf{x})\} \quad (1)$$

où $K_i(\mathbf{x})$ est exprimé par :

$$K_i(\mathbf{x}) = (\mathbf{x} - \boldsymbol{\mu}_i)^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) - 2 \log(P(C_i)) \quad (2)$$

où $\boldsymbol{\mu}_i$ est le vecteur des moyennes de la faute F_i , $\boldsymbol{\Sigma}$ est la matrice de variance-covariance commune et $P(C_i)$ est la probabilité a priori de la classe C_i .

B.2 k plus proches voisins

L'algorithme des k plus proches voisins est un outil de classification non paramétrique (sans estimation de paramètres). Le principe de cette méthode est d'observer les k plus proches voisins d'une nouvelle observation à classer. Pour cette nouvelle observation, l'algorithme calcule la distance de cette observation à chaque observation d'un ensemble d'apprentissage. Alors, étant données les distances, on peut sélectionner les k plus proches voisins et donc leurs classes respectives. Considérant les classes des k plus proches voisins, on peut conclure sur la classe de la nouvelle observation. Afin d'illustrer cette règle, un exemple de classification à deux classes dans un espace à deux dimensions est donné sur la figure 2.




Fig. 2. Exemple d'attribution de classe pour l'algorithme à 3 plus proches voisins

B.3 Séparateur à vaste marge

Le séparateur à vaste marge est un nouvel outil d'apprentissage automatique spécialement conçu pour la classification, la prévision et l'estimation dans les cas où peu d'observations sont disponibles [12]. À l'origine, les SVM sont seulement applicables à des problèmes linéaires : un algorithme SVM recherche la séparation linéaire maximisant la marge entre deux classes. Mais grâce à l'astuce du noyau (kernel trick) [13], il est possible de traiter des problèmes non linéaires. Pour une meilleure compréhension, un exemple est donné sur la figure 3. La première figure représente deux classes non linéairement séparables. Une transformation de l'espace initial (x) vers un espace bidimensionnel ($x; x^2$) permet de séparer linéairement et correctement (avec la marge maximale) les deux classes.




Fig. 3. Principes du SVM

B.4 Réseaux Bayésiens classifieurs

Un Réseau Bayésien (RB) est un graphe [14]. Dans ce graphe, chaque noeud est une variable pouvant être discrète ou continue. Les arcs de ce graphe représentent des dépendances entre les variables jointes. Les classifieurs Bayésiens sont une classe particulière de RB [15]. Ils possèdent toujours un noeud discret (noeud de classe) codant les différentes classes, les autres représentent les descripteurs (ou variables) de la tâche de classification. Un type particulier de classifieur Bayésien est le Réseau Bayésien Naïf (RBN). Dans un RBN, le noeud de classe est lié à tous les autres comme indiqué sur la figure 4. Ce classifieur fait l'hypothèse forte de non-corrélation entre les variables, ce qui n'est pas très réaliste. Afin de prendre en compte les variables corrélées, certaines approches ont été développées comme les réseaux Bayésien augmenter par un arbre (Tree Augmented Naïve Bayesian networks (TAN)) proposé par Friedman [15].




Fig. 4. Différents classifieurs Bayésiens : RBN (a) et TAN (b)

B.5 Arbres de décision

Un Arbre de Décision (AD) consiste en une série de questions organisées hiérarchiquement suivant une structure arborée. Ces questions portent sur les attributs du

système. Ces attributs peuvent être des variables binaires, nominales, ordinales ou quantitative, alors que les classes doivent être de type discrètes (ou qualitatives). Étant donné un ensemble d'apprentissage, un AD produit une séquence de règles (ou une série de questions) qui peut être utilisée pour reconnaître la classe [16]. Un exemple d'un AD construit est donné sur la figure 5.

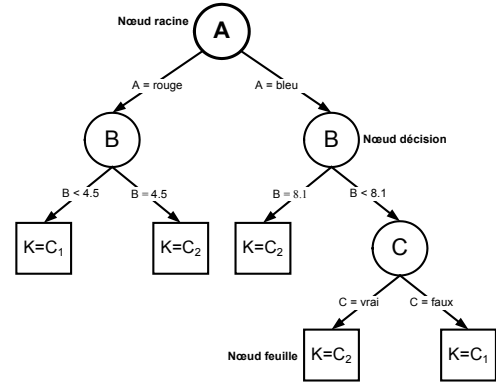


Fig. 5. Exemple d'un Arbre de Décision

III. NOUVELLES COMPOSANTES POUR LE DIAGNOSTIC DE FAUTES

A. Obtention de nouvelles informations

Généralement, une mauvaise classification est due à certaines classes partageant un même lieu dans l'espace, comme montré sur la figure 6. Sur cette figure, nous pouvons voir que les fautes possèdent un espace similaire où la décision n'est donc pas très évidente. C'est généralement à cet endroit qu'une mauvaise décision est prise.




Fig. 6. Espace similaire entre 2 classes

Dans un problème de classification supervisée classique, il n'y a pas réellement de solutions pour palier à ce problème. Mais, dans le cas de la classification supervisée appliquée au diagnostic de fautes on peut trouver une solution. En effet, la classification pour le diagnostic de fautes utilise seulement les données de précédentes observations de fautes afin de définir les classes. Or, nous avons généralement une autre information à disposition : les données provenant du mode normal de fonctionnement. L'idée de cet article est que si l'information entre les classes

n'est pas assez suffisante pour obtenir un bon taux de classification, nous pouvons ajouter au modèle des informations provenant de la différence des fautes par rapport au mode normal de fonctionnement. Ainsi, nous devons rechercher de nouvelles composantes (provenant de la différence entre une faute et les conditions normales de fonctionnement) qui vont permettre de réduire ou de supprimer le lieu d'indécision de la figure 6, comme représenté sur la figure 7.




Fig. 7. Ajout d'une nouvelle composante

B. Calcul des probabilités

Afin de d'obtenir de nouvelles composantes, nous exploitons les données du mode normal de fonctionnement. Pour cela nous utilisons une méthode précédemment proposée. À la base, cette méthode a été conçue afin d'identifier les variables responsables d'une observation fautive. Pour l'identification de fautes, l'une des techniques statistiques les plus intéressantes est la décomposition MYT [17] qui décompose la statistique T^2 dans des composantes orthogonales permettant de déterminer quelles variables ou groupes de variables ont contribué à la faute. Récemment, Li et al. [18] ont proposé une amélioration de la décomposition MYT : la décomposition causale du T^2 . Afin de réaliser cette décomposition, les auteurs utilisent un réseau Bayésien causal [14] représentant les différentes variables du procédé en fonctionnement normal. Nous avons proposé une extension à cette méthode [19], toujours basée sur un réseau Bayésien. Dans notre méthode, une observation fautive est donnée au réseau, celui-ci calcule alors pour chaque variable la probabilité d'être responsable de la situation fautive. Un exemple d'un tel réseau Bayésien est présenté sur la figure 8.

Sur la figure 8, chaque cercle représente une variable du système et la connexion entre deux variables représentent une régression de la première sur la seconde. Chaque carré (un pour chaque variable du système) représente une variable bimodale codant la responsabilité de sa variable connectée pour une situation fautive.

C. La méthode proposée

L'idée de cet article est d'exploiter les probabilités calculées par le réseau Bayésien afin de les intégrer en tant que composantes pour la tâche de classification et ainsi de




Fig. 8. Réseau Bayésien causal permettant le calcul des probabilités

faire décroître le taux de mauvaises classifications. Pour cela, nous faisons l'hypothèse que nous possédons d'anciennes données observées du procédé, à la fois pour les fautes connues et à la fois pour les conditions normales de fonctionnement. A partir des données du fonctionnement normal du procédé (supposé à p variables), le réseau Bayésien causal peut être construit. On peut alors présenter au réseau les données des différentes fautes. Le réseau donne les différentes probabilités (une pour chaque variable). Ainsi, nous obtenons $2 \times p$ composantes : les p composantes originales et les p nouvelles composantes (correspondant aux probabilités obtenues par le réseau Bayésien). Finalement nous pouvons entraîner un classifieur (voir section II-B) sur les $2 \times p$ composantes. De manière pratique, étant donnée une nouvelle observation fautive, les p mesures sont présentées au réseau afin d'obtenir les p probabilités. Après cela, l'ensemble des p mesures et des p probabilités sont présentées au classifieur qui prend la décision de la classe d'appartenance de l'observation fautive. Pour une meilleure compréhension de la méthode proposée, nous exposons le principe graphiquement sur la figure 9.




Fig. 9. Méthode proposée

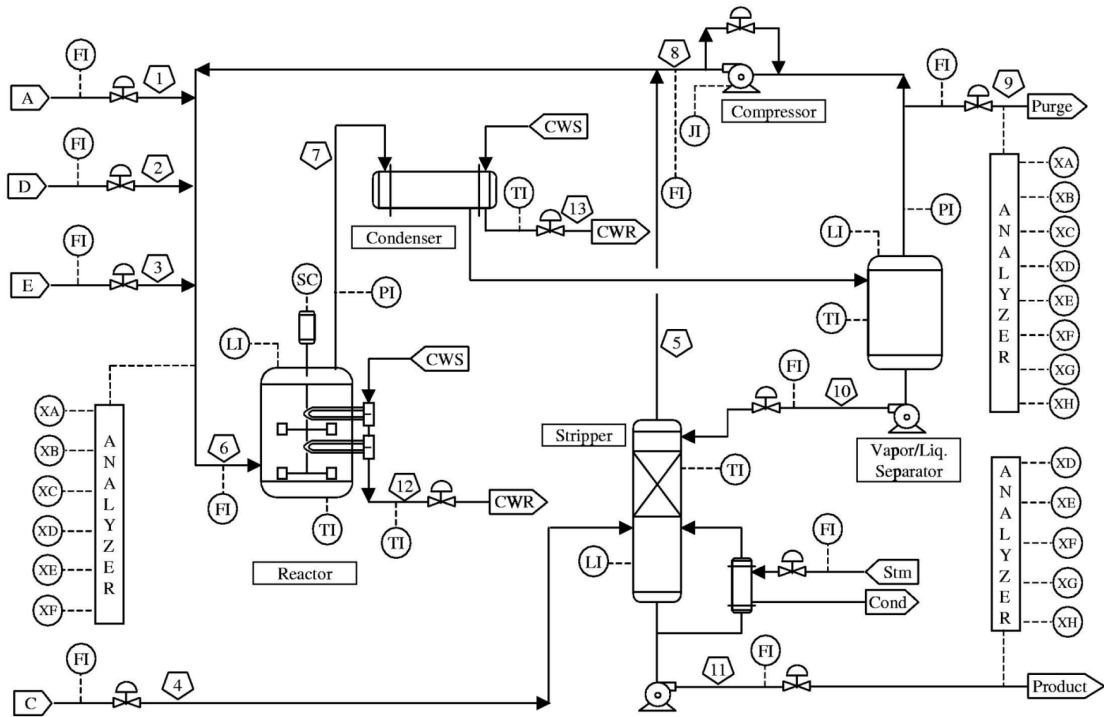


Fig. 10. Schéma du TEP

Une application de cette approche sur un problème classique : le Tennessee Eastman Process (figure 10) est présentée dans le paragraphe suivant.

IV. APPLICATION AU TEP

A. Présentation du TEP

Le Tennessee Eastman Process (TEP) est un procédé chimique. Ce n'est pas un procédé réel mais la simulation d'un procédé qui a été créé par la compagnie Eastman Chemical pour fournir un procédé industriel réaliste permettant d'évaluer des méthodes de surveillance et de contrôle des procédés. L'article de Downs et Vogel [20] décrit entièrement ce procédé. Les auteurs donnent également le code fortran de la simulation de ce procédé. Ricker [21] a implémenté la simulation sur Matlab. Le TEP est composé de cinq unités majeures de production : un réacteur, un compresseur, un décapeur, un séparateur et un condenseur. Quatre gaz réactifs et un inerte sont mélangés dans le réacteur où les produits liquides F, G et H sont formés. Ce procédé possède 12 variables d'entrée et 41 variable de sortie. Le TEP possède 20 types de fautes identifiées.

Ce procédé est idéal pour tester des méthodes de surveillance mais il est également un problème type pour les techniques de contrôle car il est instable en boucle ouverte. Beaucoup d'articles présentent et testent de nouvelles approches sur le TEP. Par exemple, pour la détection de fautes nous pouvons citer [10]. Des techniques de diagnostic de fautes ont également été testées sur le TEP [2], [22], notamment avec la structure de contrôle recommandée par [23]. Dans [22], les auteurs se focalisent sur trois types de fautes et distribuent les données qu'ils ont utilisé. Nous avons pris en compte ces trois types de fautes : faute 4, 9 et 11 (voir table I). Ces trois types de fautes sont une bonne représentation de données se chevauchant et ne sont donc

pas faciles à classer. Comme indiqué sur la table I, chaque type de fautes possède deux ensembles de données : un ensemble d'apprentissage et un ensemble de test contenant respectivement 480 et 800 observations.

Classe	Type de faute	Données App.	Données Test
1	Faute 4 : Saut de la température d'entrée du refroidissement liquide au réacteur	480	800
2	Faute 9 : Variation aléatoire de la température d'alimentation en D	480	800
3	Faute 11 : Variation aléatoire de la température d'entrée du refroidissement liquide au réacteur	480	800

TABLE I
DESCRIPTION DE LA BASE DE DONNÉES

B. Résultats et analyses

Nous avons testé différentes configurations pour cette expérimentation. Certains auteurs ont montré que pour ces trois fautes (F4, F9 et F11), seulement deux variables sont très informatives : les variables 9 et 51 (X9 et X51). Ainsi, nous avons réduit le problème de la classification de ces trois classes dans l'espace de 52 variables vers un espace de 2 variables (variables 9 et 51).

Afin de démontrer l'intérêt d'ajouter de nouvelles composantes informatives au modèle, nous avons calculé, dans chaque cas, le taux de mauvaises classifications dans l'espace à deux variables (dénommées X_9 et X_{51}), dans l'espace à deux probabilités (dénommées P_9 et P_{51}), et dans l'espace à 2 variables- 2 probabilités (dénommées X_9 , X_{51} , P_9 et P_{51}). De plus, pour montrer l'application générale de la méthode proposée nous avons utilisé différents classificateurs : Analyse Discriminante Linéaire (ADL), Arbre de Décision (AD), K plus proches voisins (avec 1 et 3 voisins, respectivement 1-PPV et 3-PPV), réseau Bayésien naïf (RBN) et augmenté par un arbre (TAN), Séparateur à Vaste Marge à fonction de base radiale (SVM). Les taux de mauvaises classifications (en pourcentage) sont présentés dans la table II : plus le taux est faible meilleure est la classification.

Classifieur	X_9, X_{51}	P_9, P_{51}	X_9, X_{51}, P_9, P_{51}
ADL	31.58	19.2	15.33
AD	9.5	12.62	8.87
1-PPV	12.87	18.87	10.7
3-PPV	11.37	15.46	8.79
RBN	11.5	16.83	9.29
TAN	10.12	16.83	8.87
SVM	7.75	16.16	7.66

TABLE II

RÉSULTATS : TAUX DE MAUVAISES CLASSIFICATIONS

Dans la table II, on peut voir que pour chaque classifieur les mêmes conclusions s'appliquent. Premièrement nous pouvons observer que pour tous les classifieur (excepté l'ADL) le taux de classification est plus faible dans l'espace original que dans l'espace des probabilités. Mais, comme proposé dans cette méthode, pour chaque classifieur, le taux de mauvaises classifications est plus faibles dans l'espace combiné (X_9, X_{51}, P_9, P_{51}) que dans les deux autres espaces (l'espace original et l'espace des probabilités). Ainsi, nous pouvons dire que les deux espaces (X_9, X_{51} et P_9, P_{51}) contiennent des informations différentes, et que donc leur combinaison est plus efficace que chaque espace pris séparément.

V. CONCLUSIONS ET PERSPECTIVES

L'intérêt principal de cet article est la présentation d'une nouvelle méthode pour le diagnostic de faute de procédé industriel. Nous avons considéré le cas où le diagnostic de fautes est vue comme une classification supervisée. Nous avons proposé d'obtenir plus d'informations que celles contenues uniquement dans la base de données de fautes. Cette information supplémentaire est contenue dans la différence des fautes au mode normal de fonctionnement. Cette différence est exprimée par des probabilités obtenues par un réseau Bayésien causal représentant le mode normal de fonctionnement du procédé. Ainsi, ces probabilités sont vues comme de nouvelles variables par le classifieur supervisé. Les performances de cette approche ont été testées sur un exemple concret : le Tennessee Eastman Process. Les résultats de la méthode sont bons et démontrent bien l'avantage de celle-ci.

Ce premier travail ouvre des perspectives intéressantes. En effet, comme nous avons travaillé sur le réseau Bayésien causal donnant les probabilités pour l'espace combiné, nous l'avons simplement réutilisé. Mais, au vu des résultats, il va être très intéressant de découvrir quelles informations donne le réseau. Peut-être que ces informations peuvent être exprimées plus précisément qu'au travers de probabilités (distances statistiques, distances de régression) et donner ainsi des résultats encore meilleurs.

RÉFÉRENCES

- [1] Rolf Isermann. *Fault Diagnosis Systems An Introduction from Fault Detection to Fault Tolerance*. Springer, 2006.
- [2] Leo H. Chiang, Evan L. Russell, et Richard D. Braatz. *Fault detection and diagnosis in industrial systems*. New York : Springer-Verlag, 2001.
- [3] D. H. Stamatis. *Failure Mode and Effect Analysis : FMEA from Theory to Execution*. ASQ Quality Press, 2003.
- [4] B.S. Dhillon. *Reliability, Quality, and Safety for Engineers*. CRC Press, 2005.
- [5] Ron J. Patton, Paul M. Frank, et Robert N. Clark. *Issues of Fault Diagnosis for Dynamic Systems*. Springer, 2000.
- [6] V. Venkatasubramanian, R. Rengaswamy, S.N. Kavuri, et K. Yin. A review of process fault detection and diagnosis part iii : Process history based methods. *Computers and Chemical Engineering*, 27(3) :327-346, 2003.
- [7] Douglas C. Montgomery. *Introduction to Statistical Quality Control, Third Edition*. John Wiley and Sons, 1997.
- [8] J.A. Westerhuis, S.P. Gurden, et A.K. Smilde. Standardized q-statistic for improved sensitivity in the monitoring of residuals in mspc. *Journal of Chemometrics*, 14(4) :335-349, 2000.
- [9] Edward J. Jackson. Multivariate quality control. *Communication Statistics - Theory and Methods*, 14 :2657 - 2688, 1985.
- [10] M. Kano, K. Nagao, S. Hasebe, I. Hashimoto, H. Ohno, R. Strauss, et B.R. Bakshi. Comparison of multivariate statistical process monitoring methods with applications to the eastman challenge problem. *Computers and Chemical Engineering*, 26(2) :161-174, 2002.
- [11] R. O. Duda, P. E. Hart, et D. G. Stork. *Pattern Classification 2nd edition*. Wiley, 2001.
- [12] Vladimir N. Vapnik. *The Nature of Statistical Learning Theory*. Springer, 1995.
- [13] A Aizerman, EM Braverman, et LI Rozoner. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control*, 25 :821-837, 1964.
- [14] Finn V. Jensen. *An introduction to Bayesian Networks*. Taylor and Francis, London, United Kingdom, 1996.
- [15] N. Friedman, D. Geiger, et M. Goldszmidt. Bayesian network classifiers. *Machine Learning*, 29(2-3) :131-163, 1997.
- [16] Leo Breiman, Jerome Friedman, Charles J. Stone, et R.A. Olshen. *Classification and Regression Trees*. Wadsworth & Brooks/Cole Advanced Books & Software, 1993.
- [17] Robert L. Mason, Nola D. Tracy, et John C. Young. Decomposition of T^2 for multivariate control chart interpretation. *Journal of Quality Technology*, 27(2) :99-108, 1995.
- [18] Jing Li, Jionghua Jin, et Jianjun Shi. Causation-based t^2 decomposition for multivariate process monitoring and diagnosis. *Journal of Quality Technology*, 40(1) :46-58, 2008.
- [19] Sylvain Verron, Teodor Tiplica, et Abdessamad Kobi. Réseaux bayésiens pour l'identification de variables hors-contrôle. *5ème Conférence Internationale Francophone d'Automatique*, Bucarest, Roumanie, 2008.
- [20] J.J. Downs et E.F. Vogel. Plant-wide industrial process control problem. *Computers and Chemical Engineering*, 17(3) :245-255, 1993.
- [21] N.L. Ricker. Decentralized control of the tennessee eastman challenge process. *Journal of Process Control*, 6(4) :205-221, 1996.
- [22] L.H. Chiang, M.E. Kotanchek, et A.K. Kordon. Fault diagnosis based on fisher discriminant analysis and support vector machines. *Computers and Chemical Engineering*, 28(8) :1389-1401, 2004.
- [23] P.R. Lyman et C. Georgakis. Plant-wide control of the tennessee eastman problem. *Computers and Chemical Engineering*, 19(3) :321-331, 1995.