



UNIVERSITE M'HAMED BOUGARA DE BOUMERDES

Faculté des Hydrocarbures et de la Chimie

Département Automatisation des Procédés Industriels et Electrification

Laboratoire d'Automatique Appliquée

THÈSE DE DOCTORAT

Présentée par

Mr HABBI HACENE

En vue de l'obtention du diplôme de Docteur en génie électrique

Option : Automatisation des Procédés Industriels

Identification et Surveillance de Processus Dynamiques Complexes par Logique Floue.

Application à un échangeur de chaleur

Soutenue publiquement le 3 juillet 2007 devant le Jury composé de :

ABBASSI Hadj Ahmed	Professeur	Université de Annaba	Président
ZELMAT Mimoun	Professeur	Université de Boumerdès	Rapporteur
BOUKHETALA Djamel	MC	ENP El-Harrach	Examineur
LAAOUAD Ferhat	MC	Université de Boumerdès	Examineur

ملخص

تعتمد اغلب الأنظمة الصناعية المتطورة حاليا في مبدأ عملها على تقنيات تحكم جد معقدة و على وسائل قياس و إنتاج جد حساسة. لهذا الغرض, يبدو من البديهي إلحاق هذه الوظائف بنظام مراقبة فعال قادر على إسقاط الصورة الفعلية لهذه الوسائل أثناء عملها و إخطار العامل بكل ما قد يشوبها من أخطاء عملية أو حالات توقف طارئ.

إن التقنيات التي يعتمد عليها مصمم أنظمة المراقبة كثيرة و متعددة الأوجه. فمنها ما يعتمد على التجربة, و منها ما يعتمد على نماذج رياضية متعلقة بالنظام الصناعي محل الدراسة. إن دقة و فعالية أنظمة الفحص و المراقبة يتعلق أساسا بدقة و مصداقية النماذج الرياضية المستعملة. انطلاقا من هذه الزاوية, نستعرض من خلال رسالة الدكتوراه هذه مقاربة لتصميم أنظمة مراقبة خاصة بالأنظمة الصناعية المعقدة باستعمال نظرية المنطق الغامض. استنادا إلى خصوصية هذه النظرية, نقترح تشكيل نماذج رياضية خاصة بالنظام الصناعي محل الدراسة و التي نستعملها فيما بعد لتصميم نظام مراقبة وفقا لخصائصه التقنية. لإبراز جدوى هذا الطرح, نستعرض تطبيقا محددا قمنا بإنجازه و المتعلق بتصميم نظام مراقبة خاص بنظام تبادل حراري يستند على مبادئ المنطق الغامض. توضح النتائج المتحصل عليها مدى أهمية المستعملة و نجاعتها في استدراك مجموعة النقائص المرتبطة بتقنيات النمذجة و المراقبة التقليدية.

Résumé

L'objectif visé dans cette thèse est de présenter et valider une approche d'identification et de surveillance pour les processus dynamiques complexes en se basant sur la logique floue. Par souci d'applications industrielles, l'accent a été exclusivement mis sur des systèmes non linéaires. Les systèmes non linéaires étant beaucoup plus difficiles à analyser que les systèmes linéaires, leur identification et surveillance sont loin d'être aussi développées et complètes. En général, les fonctions de surveillance sont étroitement liées aux méthodes d'identification qui permettent d'obtenir le modèle de référence et la conception des algorithmes de surveillance. De ce fait, le modèle identifié doit être suffisamment représentatif et moins conservatif pour permettre la détection et le diagnostic des défauts considérés, et assez flexible que possible pour ne pas nuire à la conception et l'implémentation de l'algorithme de surveillance.

Ainsi, notre contribution s'inscrit au cœur de cette problématique. En fait, nous avons pu développer une procédure complète pour la détection et l'isolation de défauts basée sur les modèles flous et l'appliquer avec succès à un échangeur de chaleur qui constitue l'élément principal d'une installation pilote du laboratoire SAAS de l'Université Libre de Bruxelles. La démarche n'était guère aisée car il a fallu donner une justification pratique à l'approche théorique en commençant tout d'abord par répondre à l'une des principales interrogations, que nous nous sommes posées, et qui concerne la capacité de l'approximation d'un modèle flou, notamment pour le cas de l'échangeur de chaleur qui fait bien partie de la classe des systèmes à paramètres distribués. Pour ce faire, il a fallu valider l'algorithme de surveillance basé sur la manipulation de ces modèles flous afin d'apporter une justification de plus aux succès de la logique floue rencontrés au niveau des applications. Comme le montrent clairement les résultats expérimentaux obtenus, il a été démontré que les modèles flous élaborés peuvent efficacement reproduire le comportement dynamique de n'importe quel processus sur un sous-ensemble compact avec un degré de précision donné. Ces modèles sont ensuite utilisés pour la synthèse d'une procédure complète de détection et d'isolation de défauts avec une concentration particulière sur le problème de fuite d'eau. Les algorithmes développés ont été implémentés et mis en œuvre avec succès sur l'installation pilote.

Abstract

The control devices which are nowadays exploited to improve the overall performance of industrial processes involve both sophisticated digital system design techniques and complex hardware. In such a way, the probability of failure occurrence on such equipment may result significant, and an automatic supervision control should be used to detect and isolate anomalous working conditions as soon as possible.

The model-based approach to fault detection and diagnosis in automated processes has received considerable attention during the two last decades. Different methods of residual generation have been discussed in the literature. In particular, the problem of residual generation for fault detection and isolation in linear time invariant (LTI) systems is deeply studied using algebraic methods in state space or in frequency domain, geometric approach and parity space approach. It is important to notice that model-based methods make use of mathematical models of the system. However, a perfectly accurate mathematical model of the physical plant is never available. Usually, the parameters of the system may vary with time and the characteristics of the disturbances and noises are unknown. Hence, there is always a mismatch between the actual process and its mathematical description even in free-fault conditions. Such discrepancies cause difficulties in fault diagnosis applications, in particular, since they act as sources of false alarms and missed alarms. The effect of modeling uncertainties, disturbances and noises is therefore the most crucial point in model-based fault diagnosis and the solution to this problem is the key for its practical applicability.

This thesis aims to define a comprehensive methodology for fault detection and isolation in nonlinear dynamic processes based on fuzzy logic theory. The fuzzy strategy is exploited for both process model identification and fault detection and isolation tasks. The diagnostic tools presented in this thesis are well illustrated using a practical application, namely a co-current heat exchanger. The new aspect consists in building a nonlinear fuzzy model that captures the key dynamical properties of the physical plant over a wide operating range. This fuzzy model is then used for leak, sensor and actuator fault detection and isolation system design for the heat exchanger plant. Decision making is built upon a statistical approach used for change detection and symptom generation purpose. The different results obtained during experiments show the effectiveness of the developed strategy.

Liste des publications

A. Articles dans des revues internationales

1. Habbi H., Zelmat M. et Ould Bouamama B. "A dynamic fuzzy model for a drum boiler-turbine system", **Automatica (Revue de l'IFAC)**, Vol. 39, Issue 7, july 2003, pp. 1213-1219, **ISSN 0005-1098**.
2. Habbi H. et Zelmat M. "Une approche améliorée pour l'optimisation des contrôleurs flous", **Journal Européen des Systèmes Automatisés, APII-JESA**, Vol. 36 – n° 4, 2002, p.579-595, **ISSN 1269-6935**.

B. Articles de conférences

1. Habbi H. et Zelmat M. "Mixed LQG/LTR and fuzzy logic strategy on a steam boiler turbine control problem", Septième Conférence Internationale des Sciences et Techniques de l'Automatique, STA'06, Tunisie (2006).
2. Habbi H. et Zelmat M. "Intelligent coordinated control scheme for improving steam power plant operations during load rejections", IEEE International conference on Computational Intelligence for Modeling, Control and Automation, CIMCA'05, vol. 2, pages 576-580, Austria (2005). Disponible sur le web: www.csd.computer.org
3. Habbi H. et Zelmat M. "Fuzzy logic based reference governor for the improved control of a drum-boiler-turbine unit", Third International Conference on Systems, Signals & Devices, Tunisie (2005).
4. Habbi H. et Zelmat M. "Dynamical modeling of a biphasic separator for hydrocarbon field", 1st conference on integrated modeling and analysis in applied control and automation, IMAACA, Italie (2004).
5. Habbi H. et Zelmat M. "Fuzzy model-based control of a drum boiler-turbine system", 1st conference on integrated modeling and analysis in applied control and automation, IMAACA, Italie (2004).
6. Habbi H. et Zelmat M. "Optimal fuzzy control system design for steam power plant", International conference on complex systems, intelligence and modern technology applications, CSIMTA, Cherbourg, France (2004).

7. Habbi H. et Zelmat M. "Design of a fuzzy model-based controller for a drum boiler-turbine system", 6th international conference on applied computational intelligence, FLINS, pages 659-664, Belgique (2004), ISBN 981-238-873-7.
8. Habbi H. et Zelmat M. "An improved self-tuning mechanism of fuzzy control by gradient descent method", in the proceeding of 17th European Simulation Multiconference ESM, pages 43-47, Nottingham, UK (2003), ISBN 3-936150-25-7.
9. Habbi H. et Zelmat M. "A fuzzy rule base for the improvement of a gradient descent-based self-tuning mechanism of fuzzy control", 2nd Conférence Internationale sur la Productique CIP'2003, Algérie (2003).
10. Habbi H. et Zelmat M. "Fuzzy logic for the description of the dynamic behavior of steam power system", 4th European Congress of Chemical Engineering ECCE-4, Granada, Espagne (2003), ISBN 84-88233-31-0.
11. Habbi H. et Zelmat M. "A drum boiler linguistic model for complexity reduction and interpretability improvement", Mini-Euro conference on Human Centered Processes: Distributed decision making and man-machine cooperation, pages 47-52, Luxembourg (2003).
12. Habbi H. et Zelmat M. "Nonlinear modeling of a boiler-turbine system using fuzzy logic approach", 5^o Journées Scientifiques et Techniques de Sonatrach, JST5, Algérie (2002).
13. Habbi H. et Zelmat M. "A Takagi-Sugeno fuzzy model for industrial boiler-turbine system with interpretability issues", 14th International Conference on Recent Advances in Soft Computing, RASC, UK (2002).
14. Habbi H. et Zelmat M. "Méthode de synthèse d'un contrôleur hybride optimal flou: Application à un problème de commande optimale d'un système non linéaire", (in french), National Seminar on Automation and Signals, SNAS, Algérie (1999).
15. Habbi H. et Zelmat M. "Commande optimale en logique floue d'un système non linéaire stationnaire perturbé", Second International Conference on Systems, Signals and Automation SSA2, Algérie (1999).

Table des matières

Abstract

Liste des publications

Introduction générale **4**

1 Etat de l'art des outils de surveillance **7**

1. Introduction 7
2. Définitions et terminologie 8
3. La surveillance de processus dans un système de supervision 9
4. Redondances physique et analytique 10
5. Classification des méthodes de surveillance 11
 - 5.1. Méthodes à base de modèles 12
 - 5.2. Méthodes sans modèles 12
6. Considérations générales sur les systèmes de surveillance 13
 - 6.1. Rapidité 14
 - 6.2. Isolabilité 14
 - 6.3. Robustesse 14
 - 6.4. Adaptabilité 14
 - 6.5. Identifiabilité de défauts 14
 - 6.6. Capacité de traitement 14
 - 6.7. Facilité d'interprétation 15
7. Commandabilité de processus et détectabilité de défauts 15
8. Conclusions 16

2 La surveillance à base de modèles **17**

1. Introduction 17
2. Principe de la surveillance à base de modèles 17
3. Caractérisation de défauts 18
4. Méthodes de génération de résidus de détection 19
 - 4.1. Génération de résidus via l'estimation paramétrique 20

4.1.1. Erreur polynomiale	20
4.1.2. Erreur de sortie	21
4.2. Génération de résidus avec un observateur	21
4.2.1. Observateur de Luenberger	22
4.2.2. Observateur à entrées inconnues (UIO)	23
4.3. Génération de résidus via l'approche espace de parité	26
5. Utilisation des observateurs pour la surveillance	28
5.1. La configuration DOS	28
5.2. La configuration GOS	29
6. Détection de changements et génération de symptômes analytiques	31
7. Conservatisme des méthodes de surveillance à base de modèles	31
8. Intégration de l'intelligence artificielle à la surveillance	32
9. Conclusions	33
3 Identification de systèmes flous en vue de la surveillance	35
1. Introduction	35
2. Identification de modèles non linéaires boîtes-noires	36
2.1. Modèles dynamiques à mémoire finie	36
2.1.1. Régresseurs	36
2.1.2. Fonctions non linéaires	37
2.1.3. Estimation de paramètres	38
3. Modèles flous de processus	38
3.1. Classification des modèles flous	39
3.2. Structure d'un modèle flou TS	40
3.3. Méthodes d'obtention des modèles flous TS	41
3.3.1. Par linéarisation dynamique	41
3.3.2. Par identification	42
4. Identification des modèles flous TS par la méthode du clustering	43
4.1. Principe du clustering	43
4.2. Algorithme de clustering de Gustafson-Kessel (GK)	44
4.3. Génération des fonctions d'appartenance	48
4.4. Estimation des paramètres	50
5. Utilisation des modèles flous TS pour la surveillance	51
5.1. Génération de résidus	52
5.2. Evaluation des résidus	53
5.2.1. Méthode de somme cumulée (CUSUM)	53
5.2.2. Paramètres de conception dans l'algorithme CUSUM	55
6. Conclusions	56
4 Application de l'approche floue à la surveillance d'un échangeur de chaleur	57
1. Introduction	58
2. Description de l'échangeur de chaleur	59

2.1. Circuit d'air	59
2.2. Circuit d'eau	60
2.3. Dispositif de chauffe	61
2.4. Grandeurs et organes de mesure	61
3. Modèle mathématique de l'échangeur de chaleur	62
3.1. Echange thermique air-métal-eau	63
3.2. Echange thermique dans le circuit d'air	63
3.3. Remarques sur le modèle mathématique établi	64
4. Identification du modèle flou de l'échangeur de chaleur	65
4.1. Résultats expérimentaux d'identification	69
4.2. Validation du modèle flou proposé	71
5. Conception du système de surveillance	73
5.1. Conception du générateur de résidus	74
5.2. Test expérimental du générateur de résidus	76
5.3. Implémentation de l'algorithme CUSUM et évaluation des résidus	83
6. Conclusions	87
Conclusions et perspectives	89
Annexe A : Paramètres physiques de l'échangeur de chaleur	92
Annexe B : Algorithme de somme cumulée (CUSUM)	94
Annexe C : Sur la simplification des modèles flous TS	94
Bibliographie	100

Introduction générale

Les plans d'instrumentation des procédés industriels modernes sont souvent complexes, impliquant des équipements très sensibles et des systèmes de régulation très sophistiqués. Pour les besoins de fiabilité et de disponibilité, ces procédés sont, dans la plupart des cas, équipés d'un système de supervision assurant des tâches bien particulières liées aux aspects sûreté de fonctionnement, surveillance et planification. Les systèmes de régulation et de supervision ont tous deux besoin de connaissances, souvent sous forme d'une représentation mathématique (modèle) qui doit tendre à ressembler le mieux possible à la réalité du processus. Le dilemme réside en fait entre la fidélité du modèle avec le processus réel et l'adéquation de ce modèle à une forme mathématiquement exploitable. Les modèles doivent être raisonnablement établis de façon à permettre la représentation de tous les modes de fonctionnement du processus, ainsi que toutes les interactions entre les différentes grandeurs. Aussi, ils doivent être suffisamment tolérants aux incertitudes, aux imprécisions et aux incomplétudes relevant de la méthode de modélisation ou d'identification utilisée.

Devant la difficulté de la tâche, et à partir de considérations physiques, on est souvent amené à admettre certaines restrictions structurelles (linéarité, stationnarité, platitude) conduisant à des approximations de modèles. Dans un premier temps, la tendance a été d'utiliser des modèles linéaires à temps invariant (LTI). L'inconvénient d'une telle approche est son aspect local, le modèle LTI n'est qu'une description locale du comportement dynamique du processus. Une approche multimodèle basée sur plusieurs modèles LTI a été élaborée ces dernières années. L'impact de cette alternative était comme même important, une multitude d'approches basées sur les multimodèles ont été rapidement développées et appliquées à des contextes variés de commande et de surveillance de processus industriels.

L'idée de s'appuyer sur des multimodèles pour réaliser un diagnostic de fonctionnement s'est vue intensivement envisagée suite à l'intégration massive des techniques de l'intelligence artificielle (AI) en automatique. Ces techniques telles que la logique floue, les réseaux de neurones et les ondelettes, pour ne citer que quelques unes, ont offert des outils puissants qui ont considérablement servi à la résolution de problèmes divers, notamment d'identification de processus dynamiques non linéaires, de classification et de reconnaissance de défauts, d'optimisation et de prise de décision. L'impact de l'intégration des techniques AI sur les méthodes conventionnelles de

surveillance à base de modèles continue d'être florissant. En fait, les techniques AI ne sont guère vues comme un substitut absolu aux méthodes de surveillance basées sur des modèles, mais sont efficacement employées pour réduire le conservatisme, voire le pessimisme, de certaines de ces méthodes, notamment au niveau de la génération et de l'évaluation de résidus qui nécessitent la manipulation de modèles assez complexes et assez flexibles pour le besoin de conception d'algorithmes de surveillance robustes.

Notre sujet de thèse ne prétend pas traiter toutes les approches pour toutes les classes de systèmes, il concerne le développement d'une approche basée sur la logique floue appliquée à l'identification et la surveillance d'un échangeur de chaleur pilote, un processus dynamique faisant parti de la classe des systèmes à paramètres distribués. Les processus distribués sont généralement régis par des équations aux dérivées partielles explicitant la variation d'une ou de plusieurs grandeurs en fonction du temps et de l'espace. Ces modèles que l'on dérive souvent à partir des lois de la physique, telles que les lois de conservation d'énergie et de matière, sont extrêmement lourds à manipuler et nécessitent d'être simplifiés, le plus souvent par la considération d'un critère de platitude. Cette approximation conduit bien à des modèles moins conservatifs, mais qui restent difficilement exploitables en raison des non linéarités que l'on peut rencontrer dans ce type de processus. Pour réduire ce pessimisme, nous avons adopté une démarche exclusivement basée sur l'utilisation des modèles flous de type Takagi-Sugeno (TS), obtenus à l'aide d'une méthode d'identification boîte-noire non linéaire basée sur la logique floue. Ces modèles sont ensuite utilisés pour la conception d'algorithmes de détection et de diagnostic de défauts.

L'étude expérimentale que nous avons menée se situe autour de trois principaux axes : le premier concerne l'identification des modèles flous TS à partir des mesures entrées-sorties à l'aide d'une méthode de partition de données, dite *clustering*, le deuxième traite le problème de la détection et du diagnostic de défauts dans l'échangeur de chaleur avec une approche basée sur ces modèles, le troisième axe est consacré à l'implémentation et la mise en œuvre des algorithmes de surveillance développés.

Cette thèse est composée de quatre chapitres et est organisée de la façon suivante :

Chapitre 1 : Ce chapitre est consacré aux notions et aux outils utilisés le long de ce document. On y trouve quelques définitions liées au domaine de la surveillance de processus reprises des actes du Comité Technique SAFEPROCESS de l'IFAC. Nous y faisons un rappel des principales notions et méthodes de détection et de diagnostic de défauts en les situant dans la littérature concernée.

Chapitre 2 : Le chapitre 2 est dédié aux méthodes de surveillance à base de modèles. Nous y présentons les différentes méthodes de surveillance qui se fondent sur l'utilisation de modèles, notamment celles basées sur les observateurs, l'estimation paramétrique et l'approche espace de parité. La génération de résidus de détection via chacune de ces approches est ensuite traitée. L'isolation des défauts par l'emploi de multiples observateurs est aussi considérée. L'objectif étant de projeter les différentes idées sur lesquelles se sont appuyées longuement les méthodes conventionnelles de

surveillance afin de ressortir certains de leurs avantages et inconvénients. Nous terminons la synthèse de ces méthodes par quelques remarques sur leur conservatisme et les contraintes de leur mise œuvre effective en milieu industriel. L'intégration des techniques de l'intelligence artificielle à la surveillance est enfin discutée pour être introduite comme une alternative (et non un substitut) qui complète et améliore la robustesse des algorithmes classiques de surveillance.

Chapitre 3 : Le chapitre 3 est intégralement consacré à l'identification des modèles flous de processus et leur utilisation pour la surveillance. Parmi les nombreuses méthodes d'obtention des modèles flous TS, nous avons principalement mis l'accent sur celles qui permettent de les obtenir par identification à partir des mesures entrées-sorties. Plus précisément, nous avons étudié la méthode de clustering de Gustafson-Kessel (GK), une méthode largement utilisée pour l'extraction automatique de la base des règles d'un modèle flou à partir d'un ensemble de données. Ce choix est guidé par le fait que l'algorithme GK est relativement simple à établir, robuste vis-à-vis les bruits de mesure et adéquat pour une implémentation en ligne. L'utilisation des modèles flous pour la conception d'algorithmes de surveillance est ensuite traitée. La détection et l'isolation de défauts sont simultanément réalisées à l'aide d'une approche multimodèle exploitant les redondances analytiques exprimées par les modèles flous. Pour le besoin d'implémentation en temps réel, nous avons jugé utile d'aborder dans ce chapitre une des méthodes d'évaluation optimale des résidus pour la prise de décision. En fait, c'est la méthode de somme cumulée (CUSUM) qui est abordée.

Chapitre 4 : L'étude expérimentale est l'objet du chapitre 4. Elle se situe au niveau de l'identification d'un échangeur de chaleur pilote et la conception et la mise en œuvre du système de surveillance. Les essais d'identification et de validation du système de diagnostic y sont exposés, les résultats expérimentaux obtenus sont analysés et discutés. Un intérêt particulier a été réservé à l'étude du problème de fuite dans l'échangeur de chaleur, en raison de la nature de ce défaut qui survient fréquemment en milieu industriel et qui provoque généralement des dégradations graduelles difficilement détectables. Pour compléter la procédure de détection et d'isolation des défauts de capteurs, d'actionneurs et de fuite considérés, un mécanisme de prise de décision se basant sur l'algorithme CUSUM a été implémenté.

Chapitre 1

Etat de l'art des outils de surveillance

1. Introduction

L'augmentation de la fiabilité, de la disponibilité et de la sûreté de fonctionnement des processus technologiques demeure jusqu'aujourd'hui l'un des enjeux les plus importants de l'automatisation. Dans un premier temps, l'automatisation des processus de production a surtout fait appel aux techniques d'optimisation avec l'objectif d'augmenter la productivité en implantant des stratégies de commande performantes. Quoique extrêmement importante, cette méthodologie a tout de même conduit à un échec partiel car, d'un point de vue pratique, il était difficile, voire impossible, d'élaborer des lois de commandes à appliquer aux processus par la seule considération d'un ou de plusieurs critères de productivité. La principale raison tient à la difficulté d'établir une caractérisation complète et réellement représentative des différents modes de fonctionnement possibles d'un processus physique.

Ces constats ont rapidement dépêché la mise en œuvre de systèmes de surveillance dont l'objectif est d'être capables, à tout instant, de fournir l'état de fonctionnement des différents organes constitutifs d'un processus technologique quelconque. Il s'agit là, pour rappel, d'une plate-forme intégrée qui s'intéresse à la fois à la commande des processus de production, et aux aspects sûreté de fonctionnement, diagnostic et supervision. De manière schématique, on peut faire assigner à cette automatisation intégrée l'objectif de la conception et de la mise en œuvre, sur un processus complexe de production, la structure hiérarchisée de la figure 1.1.

La littérature concernée par ce domaine de recherche est abondante. La situation est de plus en plus florissante surtout avec l'intégration des nouvelles techniques de l'automatique. Pour une meilleure appréhension des outils utilisés dans le domaine de la surveillance et de la supervision des processus industriels, il convient de revenir sur les nombreuses revues de Gertler [GER 88; GER 91; GER 95], Patton [PAT 99; PAT 01], Frank [FRA 97a; FRA 97b; FRA 97c; FRA 00] et Isermann [ISE 84; ISE 97; ISE 98].

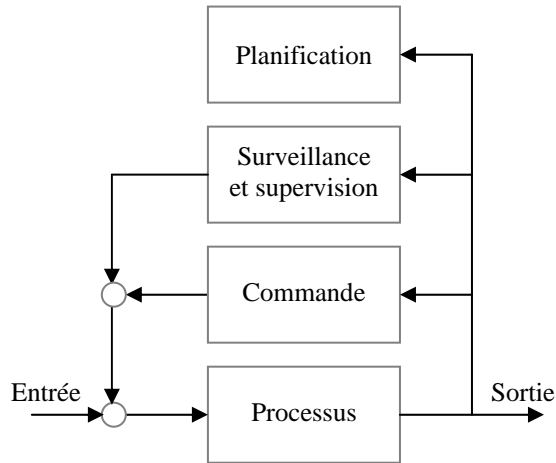


Figure 1.1 : L'automatisation intégrée.

Dans ces revues, pour ne citer que quelques unes, les problèmes de surveillance de processus sont abordés dans des contextes aussi bien méthodologiques que conceptuels. D'autres applications relevant du domaine de la surveillance des procédés industriels peuvent être consultés dans les articles listés à la fin de ce document.

2. Définitions et terminologie

Lors du passage en revue d'une dizaine de références bibliographiques, nous avons rapidement pu constater que la terminologie relative au domaine de la détection et du diagnostic de défauts n'obéit pas encore à un formalisme unifié, ce qui rend parfois difficile l'appréhension des contributions apportées dans certains articles. Dans cette thèse, nous utilisons la terminologie établie par le Comité Technique SAFEPROCESS de l'IFAC [ISER 97]. Les principales définitions sont sommairement reprises dans ce qui suit.

- **Défaut** : Généralement perçu comme une déviation dans les caractéristiques attendues (usuelles ou acceptables) du processus lui-même, des capteurs, des actionneurs ou de tout autre équipement constitutif de l'installation surveillée.
- **Défaillance** : Une interruption permanente de la capacité du processus à remplir une fonction requise dans des conditions d'exploitation spécifiées.
- **Dysfonctionnement** : Une irrégularité intermittente survenant au niveau d'une fonction remplie par le processus.
- **Résidu** : Un indicateur de défauts basé sur la différence entre les mesures et les calculs.

- **Symptôme analytique** : Un changement dans les caractéristiques nominales d'une quantité observable provoqué par un défaut.
- **Détection de défauts** : Détermination des défauts présents dans le processus et de l'instant de leurs occurrences.
- **Isolation de défauts** : Localisation et détermination du type et de l'instant d'occurrence d'un défaut.
- **Identification de défauts** : Détermination de la taille et de l'évolution temporelle d'un défaut.
- **Diagnostic** : Localisation et détermination du type, de la taille et de l'instant d'occurrence d'un défaut. Le diagnostic regroupe les étapes d'isolation et d'identification de défauts.
- **Défaut abrupt** : Un défaut avec un comportement discontinu caractérisant une panne brutale de l'élément en question : arrêt total ou partiel, déconnexion.
- **Défaut intermittent** : C'est un cas particulier du défaut abrupt avec la propriété que le signal revient de façon aléatoire à sa valeur nominale.
- **Défaut graduel** : Ce type de défaut caractérise les dégradations lentes (fuite, usure, encrassement). Il est difficile à détecter car son évolution temporelle possède la même signature que celle d'une variation paramétrique due à la non stationnarité d'un processus.

3. La surveillance de processus dans un système de supervision

Dans sa fine description du système de supervision, Rolf Isermann décrit clairement les interactions au sein d'un tel système [ISE 84]. En fait, l'objet de la supervision est de signaler les modes de fonctionnement anormaux (non désirés ou interdits) et prendre ou d'aider à prendre les actions appropriées de façon à éviter une dégradation des performances du processus ou une dégradation du processus lui-même. Dans un système de supervision, on recense un certain nombre de niveaux, principalement de surveillance, de sécurité et de prise de décision.

La détection et le diagnostic de défauts, appelés aussi surveillance [ZHA 99], sont des tâches primordiales pour la supervision des procédés industriels. On peut distinguer deux types de surveillance, l'un détecte rapidement des défaillances graves pour assurer la sécurité, l'autre détecte des dégradations lentes pour optimiser la maintenance. Le deuxième type est le plus adapté à la maintenance conditionnelle¹ qui vise à améliorer le

¹ Dans la maintenance conditionnelle, on s'intéresse à la surveillance de dégradations lentes. Les dégradations graves sont l'objet de la maintenance systématique.

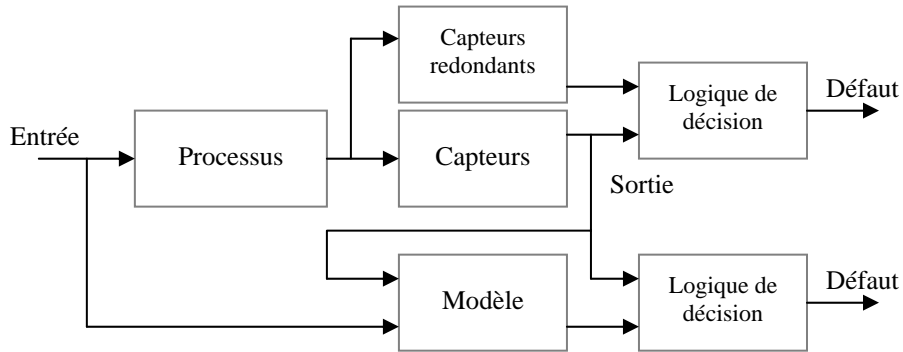


Figure 1.2 : Redondances physique et analytique.

rendement de production sans le faire au détriment de la sécurité. En présence de défauts, le système de surveillance est appelé à générer des alarmes permettant aux opérateurs de prendre les actions appropriées pour ramener le processus à son mode de fonctionnement normal. Dans le cas où cette situation est jugée sérieuse, des actions de reconfiguration ou de sécurité immédiate peuvent être effectuées.

Les techniques de détection et de diagnostic de défauts peuvent s'appliquer soit sur les signaux acquis directement sur l'installation, soit sur les résultats de traitements élémentaires portant sur ces signaux, par exemple le spectre fréquentiel de ceux-ci [DID 03]. Les efforts de recherche visent actuellement à améliorer et à automatiser la tâche de supervision de manière à obtenir une image plus précise du processus surveillé et à agir efficacement en cas de défaillances graves ou encore de dégradations lentes.

4. Redondances physique et analytique

Une première approche, traditionnellement utilisée en pratique, pour la surveillance de processus consiste à multiplier les chaînes de mesure. Cette redondance, dite physique ou matérielle, permet une détection voire une localisation des capteurs défaillants. La fiabilité et la simplicité de la méthode ont, pour contrepartie, un surcoût de l'installation et une diminution du temps moyen de bon fonctionnement. Un autre inconvénient est que les composantes identiques fabriquées dans la même série peuvent se dégrader de la même façon et tomber en panne en même temps.

Pour palier à ces inconvénients, une alternative basée sur l'exploitation de la redondance informationnelle contenue implicitement dans un ensemble de mesures a été initiée pour la première fois par Beard en 1971 [BEA 71]. Cette méthode, appelée redondance analytique, consiste à utiliser des informations supplémentaires issues de modèles générant des grandeurs homogènes à celles provenant de capteurs. Elle vient en complément à la redondance matérielle et permet la détection et la reconnaissance de

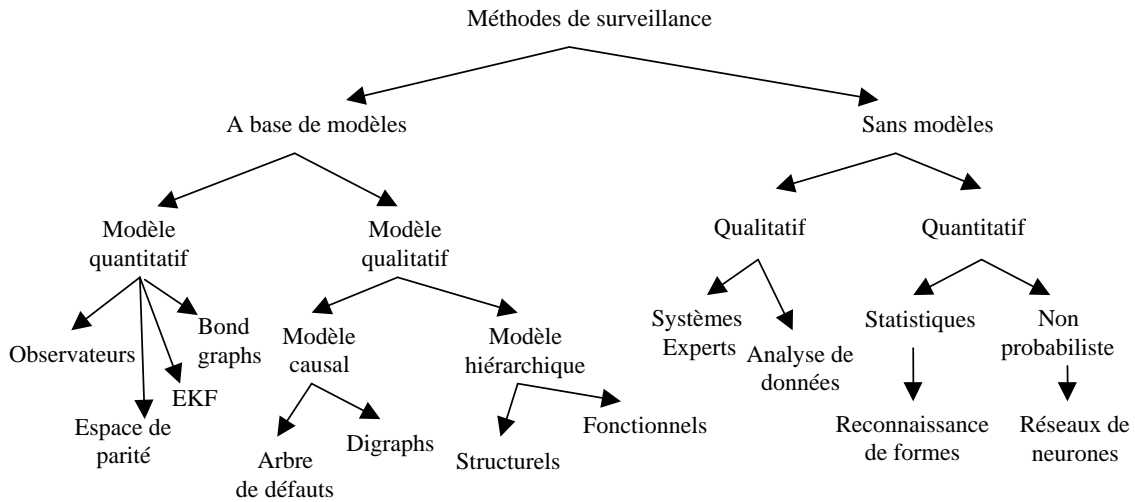


Figure 1.3 : Classification des méthodes de surveillance.

défauts affectant le processus lui-même, les capteurs et les actionneurs. Il convient de noter que l'utilisation des techniques de redondance analytique repose sur la disponibilité d'un modèle de connaissance ou de représentation du processus surveillé.

Dans un schéma de redondance analytique, la première phase concerne la génération de résidus caractéristiques du défaut. Les résidus représentent les écarts entre le comportement observé du processus et le comportement de référence attendu en fonctionnement normal. Ils sont généralement à moyenne nulle et ont une variance déterminée en l'absence de défauts. Les résidus peuvent s'obtenir à l'aide des deux approches suivantes :

- par une approche physique basée sur l'utilisation d'un modèle de connaissance. Les résidus traduisent dans ce cas le degré de satisfaction des lois de la physique ;
- par une approche mathématique autour d'un formalisme de représentation qui conduit au concept d'espace de parité.

La figure 1.2 illustre ces concepts de redondances physique (ou matérielle) et analytique.

5. Classification des méthodes de surveillance

Les méthodes permettant d'automatiser la surveillance des processus industriels se classent généralement en deux grandes classes : celles basées sur des méthodes analytiques des domaines de l'automatique, du traitement du signal et de la statistique, et celles de l'intelligence artificielle. Notons cependant que cette partition n'est pas

aussi stricte car les techniques de l'intelligence artificielle² peuvent être utilisées pour établir des modèles de comportement du processus surveillé. Dans certaines revues [VEN 03a; VEN 03b], les méthodes de surveillance sont classées selon le type de connaissances disponibles sur le processus surveillé. On distingue alors les méthodes basées sur l'utilisation de modèles (qualitatifs ou quantitatifs) et les méthodes sans modèles (Fig. 1.3).

5.1. Méthodes à base de modèles

Ce sont des méthodes qui se fondent sur l'utilisation d'un modèle de connaissance ou de représentation construit à partir de la physique du processus ou d'une expertise humaine. Elles impliquent une connaissance à priori du fonctionnement du processus surveillé que l'on traduira sous forme de relations mathématiques (modèle quantitatif) ou de relations de cause à effet (modèle qualitatif). Les différentes approches basées sur l'utilisation de modèles quantitatifs peuvent être résumées à quelques méthodes génériques parmi lesquelles on recense l'approche observateurs, ou plus généralement reconSTRUCTEURS d'état ou de sortie (observateurs de Luenberger ou filtres de Kalman), l'approche espace de parité, l'approche estimation paramétrique ou encore les bonds graphs. Les méthodes de surveillance basées sur l'utilisation de modèles feront l'objet du chapitre 2.

5.2. Méthodes sans modèles

Ce sont des méthodes qui supposent que la seule connaissance disponible sur le processus se limite à son observation passée et présente (historique). Elles reposent principalement sur l'expertise humaine confortée par un solide retour d'expérience. L'historique constitue une base de données servant à l'extraction de descripteurs dans les différents modes de fonctionnement (sain et défaillants) du processus surveillé. Pour extraire ces descripteurs, des méthodes quantitatives et qualitatives peuvent être employées [VEN 03b].

Dans le premier cas, des approches statistiques et non statistiques sont utilisées. Les méthodes d'analyse en composantes principales (PCA) et celles de reconnaissance de formes sont les outils privilégiés pour la classification de signatures associées aux modes de fonctionnement sain et défaillants dans l'approche statistique. Les réseaux de neurones artificiels, bien reconnus par leur propriété d'approximation universelle et leur puissant procédé d'apprentissage [REN 95], sont l'une des plus importantes classes des approches de surveillance non statistiques. Un problème de diagnostic par réseaux de neurones peut se définir comme un problème de classification de défauts dans des formes acquises dans une procédure d'apprentissage. Dans le deuxième cas, les systèmes experts ou encore l'approche QTA (*Qualitative Trend Analysis*) sont utilisés.

² L'expression "intelligence artificielle" a été proposée par John McCarthy, du Massachusetts Institute of Technology, en 1956.

Les principales méthodes de surveillance sans modèles et certaines de leurs applications sont décrites avec plus de détails dans les travaux de Venkatasubramanian *et al.* [VEN 03b].

6. Considération générales sur les systèmes de surveillance

Les algorithmes de détection et de diagnostic de défauts établis à l'aide d'une méthode quelconque de surveillance sont généralement soumis à des critères d'évaluation strictes visant à vérifier leur efficacité et leur aptitude à détecter et à isoler simultanément les différents types de défauts. Nous résumons dans la suite les caractéristiques désirées d'un système de surveillance telle que décrites par Venkatasubramanian dans [VEN 03a].

6.1. Rapidité

Le système de surveillance doit réagir rapidement dans les situations de dysfonctionnement affectant le processus surveillé, et ce afin de permettre aux opérateurs d'entreprendre, le plus rapidement possible, des actions correctives appropriées. La rapidité à la détection de défauts est cependant souvent compromise avec l'exigence de performance requise en fonctionnement normal [WIL 76] : trop rapide est le système de surveillance, élevée est sa sensibilité aux bruits de mesure. Un tel compromis aura pour conséquence d'augmenter la probabilité de fausses alarmes.

6.2. Isolabilité

L'isolabilité est par définition l'aptitude du système de surveillance à distinguer les différents modes de dysfonctionnement du processus. Cette propriété est étroitement liée aux caractéristiques du processus surveillé et à la qualité du modèle utilisé pour la conception de l'algorithme de surveillance. Il existe en fait un sérieux compromis entre isolabilité et insensibilité aux incertitudes liées à la modélisation. Notons que pour le besoin de détection de défauts, la génération d'un seul résidu est suffisante, alors que pour isoler les défauts survenus, un ensemble de résidus doit être envisagé.

6.3. Robustesse

Il s'agit de vérifier l'aptitude du système de surveillance à détecter et à isoler les défauts affectant le processus surveillé dans un environnement entièrement incertain. Dans les méthodes de surveillance à base de modèles, cette exigence se traduit par la génération de résidus devant être insensibles aux incertitudes et, en même temps, sensibles aux défauts, donc robustes. Les incertitudes, dont les effets sont difficilement séparables de ceux des défauts, sont principalement dues aux variations paramétriques,

aux non linéarités dans le processus, aux erreurs de modèle ou encore aux perturbations et aux bruits de mesure affectant le processus surveillé.

Il convient de noter que le critère de robustesse concerne non seulement les méthodes de génération de résidus mais aussi les méthodes d'évaluation. Considérée comme étant une approche passive [FRA 97a], l'évaluation robuste des résidus avait tout particulièrement concerné le problème de seuillage avec l'objectif d'éliminer, voire de minimiser, les fausses alarmes. Une loi empirique de seuillage adaptatif a été initialement proposée par Clark [PAT 99], vient ensuite la méthode du sélecteur de seuil développée par Emami-Naeini dans [NAE 88]. Cette dernière consiste à définir une loi d'adaptation du seuil en fonction des incertitudes et des propriétés statistiques du bruit. D'autres méthodes d'évaluation faisant appel à des approches purement statistiques ont été développées dans la littérature [BAS 93]. Nous reviendrons sur l'une de ces approches dans le chapitre 3.

6.4. Adaptabilité

En milieu industriel, les perturbations et le changement des conditions d'exploitation influent considérablement sur les paramètres et les points de fonctionnement du processus surveillé. Un système de surveillance efficace doit être en mesure de s'adapter au mieux à ces variations qui peuvent constituer une source inévitable de fausses alarmes. Parmi les orientations privilégiées dans ce sens, citons, à titre d'exemple, la manipulation de modèles non linéaires ou de multimodèles pour la conception des algorithmes de surveillance. Malgré les difficultés de leur mise en œuvre, les méthodes de conception basées sur les observateurs adaptatifs peuvent être aussi envisagées.

6.5. Identifiabilité de défauts multiples

L'aptitude d'un système de surveillance à identifier simultanément plusieurs défauts est une caractéristique importante mais généralement difficile à réaliser. En fait, les défauts peuvent interagir en pratique et, par conséquent, le système de surveillance devient incapable de traiter les effets combinés de ces défauts à partir de leurs formes individuelles. D'autres part, la considération des différentes combinaisons possibles de défauts lors de la conception de l'algorithme de surveillance n'est pas une tâche triviale, notamment pour les processus à grandes échelles. Le problème d'identification de défauts multiples est désormais ouvert et est souvent traité en tenant compte des spécifications propres à l'application appréhendée.

6.6. Capacité de traitement

Les systèmes de surveillance intégrés dans les plans d'automatisation des processus industriels modernes impliquent souvent des solutions basées sur des algorithmes et des




Figure 1.4 : Sous-systèmes commandable et non commandable d'un processus dynamique en présence de défauts.

auxiliaires relativement complexes nécessitant une capacité de traitement de données importante. Lors de l'implémentation du système de surveillance, il est important de rechercher à réaliser l'équilibre entre ces deux exigences compétitives. Pour ce faire, l'effort de modélisation doit être dosé et considéré avec plus d'intérêt si l'on cherche à implémenter des solutions plus ou moins performantes, surtout pour les méthodes basées sur l'utilisation de modèles.

6.7. Facilité d'interprétation

En plus de son aptitude à identifier la source de dysfonctionnement du processus, le système de surveillance doit être capable de fournir des explications complémentaires concernant, par exemple, l'origine des défauts et la manière dont ils sont propagés, afin de permettre à l'opérateur d'évaluer la situation et de prendre les décisions appropriées. Cela nécessite l'exploitation de l'expérience humaine dans la base de connaissances qu'utilise l'algorithme de surveillance ; une démarche qui devient de plus en plus envisageable avec l'intégration croissante des techniques de l'intelligence artificielle, notamment la logique floue et les réseaux de neurones artificiels [REN 95]. Notons que la logique floue, et en liaison avec la théorie du raisonnement approximatif [YAG 94], offre bien la possibilité de manipuler des connaissances à la fois qualitatives et quantitatives, ce que peu d'autres méthodologies autorisent.

7. Commandabilité de processus et détectabilité de défauts

Puisque la qualité du modèle est d'une importance fondamentale pour la détection et l'isolation de défauts, nous jugeons utile d'aborder dans cette section les caractéristiques désirées des modèles utilisés pour la conception d'algorithmes de surveillance en comparaison avec ceux manipulés en commande.

En fait, les modèles utilisés en commande représentent le comportement dynamique entrée-sortie du processus commandé. L'analyse et la synthèse des lois de commande se

basent essentiellement sur ces modèles qui doivent être, en général, simples et faciles à manipuler. En effet, il s'agit de modèles simplifiés ou linéarisés ne couvrant que le domaine de fonctionnement dans lequel le système de commande est appelé à opérer. Ce n'est justement pas le cas en surveillance où l'on est souvent amené à manipuler des modèles suffisamment représentatifs du processus surveillé, donc relativement complexes par rapport à ceux utilisés en commande. Pour permettre la détection et l'isolation de défauts, nous avons beaucoup plus besoin de la partie du modèle (complexe) qui reflète les défauts considérés et qui n'est pas affectée, voire faiblement affectée, par les perturbations et les incertitudes. Afin d'extraire cette partie (sous-modèle), nous devons tenir compte du type et du nombre de défauts à détecter, ainsi que des mesures disponibles [FRA 00].

En pratique, la quantité d'information que contient un modèle destiné à la commande ne doit nécessairement pas être aussi importante que celle contenue dans un modèle utilisé pour la surveillance. Envisageons, par exemple, le cas de défauts survenant dans la partie non commandable mais observable d'un processus surveillé. Pour le besoin de commande, une réalisation minimale basée sur la décomposition canonique de Kalman peut être satisfaisante. Les modes non commandables du modèle initial ne seront plus présents dans le modèle réduit. Cette perte d'information (partie non commandable) est néanmoins nécessaire pour la détection et l'isolation des défauts affectant les variables éliminées dans le modèle réduit (Fig. 1.4). Cela explique la nécessité de manipuler des modèles d'ordres élevés et de complexité relativement prononcée si l'on désire concevoir un système de surveillance efficace et robuste.

8. Conclusions

Dans ce premier chapitre, nous avons rassemblé les notions et les outils de base utilisés dans le domaine de la surveillance des processus industriels. En passant en revue un certain nombre de publications et d'ouvrages, nous avons pu remarquer que la terminologie relative à ce domaine n'est pas vraiment cohérente. L'absence d'une base commune rend parfois difficile l'appréhension des contributions apportées dans certains articles. Afin d'éviter toute confusion, nous avons explicité quelques définitions discutées au sein du Comité Technique SAFEPROCESS de l'IFAC. Ensuite et après avoir rappelé les principales classes des méthodes de surveillance, un accent particulier a été mis sur les notions de commandabilité de processus et de détectabilité de défauts en s'inspirant des travaux de Frank [FRA 00]. Dans ce sens, nous avons pu ressortir des remarques concernant le niveau de modélisation à considérer suivant que l'on s'oriente à une application en commande ou en surveillance.

Chapitre 2

La surveillance à base de modèles

1. Introduction

Dans les techniques traditionnelles de l'automatique, les problèmes de surveillance et de supervision de processus complexes sont abordés numériquement en utilisant essentiellement les propriétés des équations différentielles caractérisant le modèle. La surveillance à base de modèles se fonde sur l'utilisation d'un modèle de comportement construit à partir de la physique du processus ou d'une expertise humaine. Elle implique une connaissance approfondie du fonctionnement sous la forme de modèles mathématiques qui devront obligatoirement être validés expérimentalement avant toute utilisation. Le modèle servant directement de référence pour la détection de défauts, la qualité du résultat dépend fondamentalement de la qualité de ce modèle.

La mise en œuvre des méthodes de surveillance à base de modèles nécessite une modélisation précise, suffisamment tolérante aux incertitudes. Pour assouplir cette contrainte, des approches se basant sur des critères de robustesse ont été développées [ISE 94; NAE 88; SIM 02]. Ce problème a été aussi soulevé par Frank dans [FRA 97a], avec une concentration particulière sur les erreurs de modèles structurées et non structurées. Dans d'autres travaux, des approches basées sur l'utilisation de multimodèles ont été proposées pour la conception d'algorithmes de surveillance robustes [ALC 03; DEX 97; ICH 01; PAT 01]. Dans ce chapitre, nous introduisons des notions élémentaires sur la détection et le diagnostic de défauts, avant de résumer les principales méthodes de surveillance basées sur des modèles.

2. Principe de la surveillance à base de modèles

La plupart des méthodes de surveillance se décomposent en deux étapes : la génération et l'évaluation de résidus de détection. Lors de la première étape, les signaux d'entrée et de sortie du processus sont utilisés pour générer un résidu, c'est-à-dire un

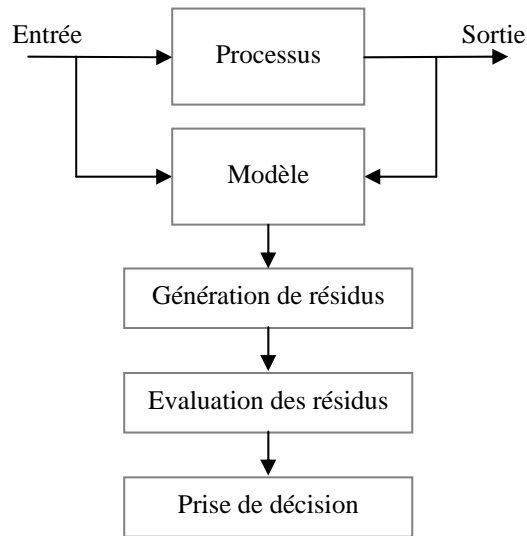


Figure 2.1 : Structure générale d'un système de surveillance à base de modèles.

signal mettant en évidence la présence d'un défaut. En général, en régime de fonctionnement normal, ce signal est statiquement nul et s'écarte notablement de zéro en présence de défauts. La structure du générateur de résidus est cependant liée à la méthode de surveillance utilisée.

Dans la seconde étape, les résidus sont analysés pour décider de la présence ou non de défaut, sur quel composant du processus il est intervenu (localisation) et, dans certains cas, déterminer la nature du défaut et sa cause (identification). L'évaluation des résidus n'est donc pas une tâche triviale. Selon le cas, elle peut s'effectuer à l'aide d'un simple test de dépassement de seuil ou doit être formulée dans un cadre statistique [BAS 93; BLA 03]. D'un point de vue pratique, la logique de décision à seuils joue un rôle important car la plupart des méthodes citées dans la littérature se ramènent, à terme, à un seuillage. La valeur du seuil est souvent inspirée de l'expérience des opérateurs en tenant compte des spécifications propres au processus surveillé. Pour le besoin de la maintenance conditionnelle, et afin de détecter les dégradations lentes, des approches à seuils adaptatifs évoluant en fonction du point de fonctionnement du processus surveillé ont été envisagées pour certaines applications [ISE 98; NAE 88; DIN 91]. Les résultats d'évaluation sont ensuite utilisés pour émettre une décision appropriée. La figure 2.1 illustre l'architecture générale d'un tel système de surveillance.

3. Caractérisation de défauts

Les méthodes de surveillance basées sur des modèles nécessitent de formuler les défauts dans les modèles qui expriment les redondances analytiques. Dans certains cas,

on se contente de rajouter des termes additifs dans le modèle décrivant le régime de fonctionnement sain du processus surveillé. Par exemple, dans un modèle d'état linéaire à temps discret :

$$\begin{aligned}\mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{f}_u(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}\mathbf{u}(k) + \mathbf{f}_y(k)\end{aligned}\tag{2.1}$$

où $\mathbf{x}(k) \in \mathfrak{R}^n$, $\mathbf{u}(k) \in \mathfrak{R}^r$ et $\mathbf{y}(k) \in \mathfrak{R}^m$, les termes $\mathbf{f}_u(k)$ et $\mathbf{f}_y(k)$ sont rajoutés pour représenter des défauts. En général, $\mathbf{f}_u(k)$ est utilisé pour représenter les défauts d'actionneurs, et $\mathbf{f}_y(k)$ pour les défauts de capteurs. En considérant le cas général d'un processus pouvant être affecté par tous types de défauts, on peut réécrire le modèle d'état (2.1) sous la forme suivante :

$$\begin{aligned}\mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{L}_1\mathbf{f}(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}\mathbf{u}(k) + \mathbf{L}_2\mathbf{f}(k)\end{aligned}\tag{2.2}$$

où \mathbf{L}_1 et \mathbf{L}_2 des matrices de dimensions finies caractérisant les défauts représentés par le vecteur \mathbf{f} .

Une autre façon de caractériser les défauts est de les considérer comme des changements de paramètres du processus surveillé. Le mode sain du processus est caractérisé par la valeur nominale $\boldsymbol{\theta}_0$ d'un vecteur de paramètres $\boldsymbol{\theta}$. Les défauts sont caractérisés par des déviations de $\boldsymbol{\theta}$ de sa valeur nominale. La surveillance du processus se traduit alors par la détection et le diagnostic des changements de paramètres.

Il convient de noter que dans le modèle (2.2) les incertitudes dans la modélisation et dans les mesures ne sont pas prises en compte. Pour que la surveillance soit robuste aux incertitudes, il faut utiliser des modèles stochastiques et/ou des méthodes statistiques pour la détection et le diagnostic des défauts. Cet aspect est discuté avec plus de détails dans le chapitre 3.

4. Méthodes de génération de résidus de détection

De nombreuses méthodes permettant la génération de résidus en utilisant des modèles analytiques ont été proposées [GER 88; GER 91; ISE 94; ISE 97; VEN 03a]. Elles peuvent cependant être classées en trois catégories selon les notions suivantes :

- reconSTRUCTEURS d'état ou de sortie (observateurs classiques, observateurs à entrées inconnues, filtres de Kalman),
- espace de parité (statique ou dynamique, linéaire ou non linéaire),
- estimation paramétrique.

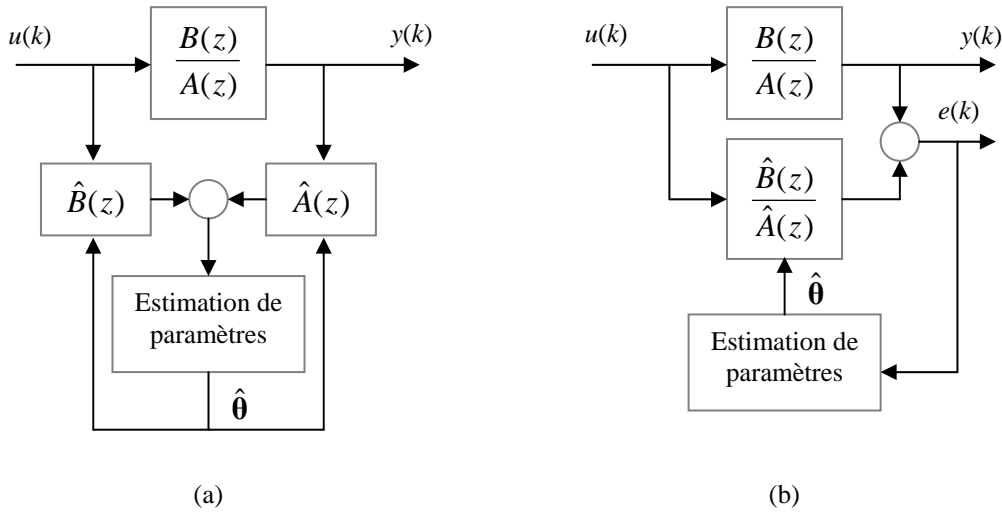


Figure 2.2 : Estimation paramétrique : (a) erreur polynomiale, (b) erreur de sortie.

Ces méthodes sont, dans la plupart, formulées pour des modèles de processus continus et discrets. Nous exposons dans la suite le cas de processus décrits par des modèles discrets mais les résultats peuvent être sans peine étendus au cas des processus continus.

4.1. Génération de résidus via l'estimation paramétrique

Dans cette approche, les défauts sont caractérisés par des changements de paramètres du processus surveillé. La structure du modèle du processus en mode sain étant supposée connue, les paramètres de ce modèle sont ensuite estimés à partir des mesures entrées-sorties. Deux formes d'erreur d'estimation peuvent être considérées : erreur polynomiale et erreur de sortie.

4.1.1. Erreur polynomiale

A titre d'illustration, considérons le cas d'un processus SISO (Fig. 2.2.a) décrit par un modèle linéaire de la forme :

$$y(k) = \varphi^T(k)\boldsymbol{\theta} \quad (2.3)$$

avec $\boldsymbol{\theta} = [a_1 \dots a_n, b_0 \dots b_m]^T$ le vecteur des paramètres et $\varphi(k)$ le vecteur des régresseurs qui est donné par :

$$\varphi(k) = [y(k-1) \dots y(k-n_y) \quad u(k-1) \dots u(k-n_u)]^T \quad (2.4)$$

où n_u et n_y des entiers caractérisant l'ordre du modèle.

L'estimateur des paramètres θ au sens des moindres carrés s'exprime par :

$$\hat{\theta} = [\varphi^T \varphi]^{-1} \varphi^T y \quad (2.5)$$

Il est obtenu par la minimisation du critère quadratique :

$$E(\theta) = \sum_k [y(k) - \varphi^T(k)\theta]^T [y(k) - \varphi^T(k)\theta] \quad (2.6)$$

Pour la mise en œuvre de cette méthode, on fait souvent appel à sa version récursive, dite la méthode du filtre de Kalman (RLS), afin d'améliorer la précision de l'algorithme d'estimation en présence des bruits de mesure.

4.1.2. Erreur de sortie

L'erreur d'estimation est, dans ce cas, une fonction non linéaire des paramètres du modèle décrivant le processus surveillé. D'après la figure 2.2.b, elle s'exprime par :

$$e(k) = y(k) - \hat{y}(\theta, k) \quad (2.7)$$

avec

$$\hat{y}(\theta, z) = \frac{\hat{B}(z)}{\hat{A}(z)} u(z) \quad (2.8)$$

Dans ce cas, la minimisation du critère d'erreur ne peut généralement se faire analytiquement. On procède souvent par voie numérique à l'aide de mécanismes d'optimisation appropriés. Néanmoins, l'effort et le temps de calcul deviennent relativement importants, ce qui complique l'utilisation en ligne d'une telle procédure.

4.2. Génération de résidus avec un observateur

Les observateurs sont souvent employés pour la reconstruction des variables d'état ou de sortie d'un processus à partir de l'observation de ses entrées et de ses sorties. Dans la littérature, de nombreuses méthodes de conception d'observateurs de diagnostic sont proposées. Il existe des méthodes géométriques [MAS 86], des méthodes basées sur la théorie spectrale [WHI 87], des méthodes fréquentielles [DIN 91] et des méthodes algébriques [FRA 00; ALC 96; ALC 98]. Nous étudions dans la suite une approche de détection de défauts utilisant un observateur classique (ou de Luenberger) et une autre

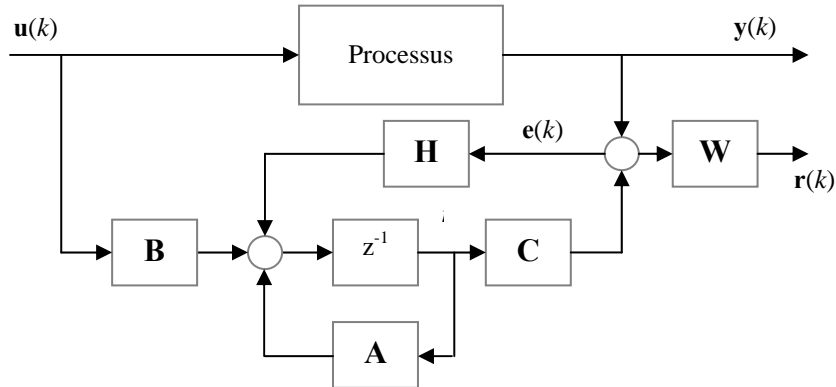


Figure 2.3 : Observateur d'état classique (de Luenberger).

approche se basant sur un observateur à entrées inconnues. La synthèse de ces deux types d'observateurs est basée sur les méthodes algébriques.

4.2.1. Observateur de Luenberger

Afin d'illustrer le principe de la méthode, considérons un processus MIMO décrit par le modèle d'état linéaire suivant :

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) \end{aligned} \quad (2.9)$$

Comme le montre la figure 2.3, la dynamique de l'observateur est régie par les équations suivantes :

$$\begin{aligned} \hat{\mathbf{x}}(k+1) &= \mathbf{A}\hat{\mathbf{x}}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{H}\mathbf{e}(k) \\ \mathbf{e}(k) &= \mathbf{y}(k) - \mathbf{C}\hat{\mathbf{x}}(k) \end{aligned} \quad (2.10)$$

où le vecteur $\mathbf{e}(k)$ désigne l'erreur de sortie et \mathbf{H} la matrice de gain de l'observateur.

L'erreur d'estimation d'état s'obtient à partir des équations (2.9) et (2.10) :

$$\begin{aligned} \tilde{\mathbf{x}}(k) &= \mathbf{x}(k) - \hat{\mathbf{x}}(k) \\ \tilde{\mathbf{x}}(k+1) &= (\mathbf{A} - \mathbf{H}\mathbf{C})\tilde{\mathbf{x}}(k) \end{aligned} \quad (2.11)$$

La matrice de gain \mathbf{H} de l'observateur résulte de la convergence asymptotique vers zéro de l'erreur d'estimation $\tilde{\mathbf{x}}(k)$, ce qui traduit la stabilité de l'observateur.

En tenant compte des perturbations et de la présence de défauts, le modèle d'état (2.9) du processus surveillé devient :

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{Q}\mathbf{v}(k) + \mathbf{L}_1\mathbf{f}(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{R}\mathbf{w}(k) + \mathbf{L}_2\mathbf{f}(k) \end{aligned} \quad (2.12)$$

Les vecteurs $\mathbf{v}(k)$ et $\mathbf{w}(k)$ représentent des perturbations agissant respectivement sur l'entrée et la sortie du processus (Fig. 2.4). On caractérise l'effet de ces perturbations par des matrices de dimensions finies \mathbf{Q} et \mathbf{R} .

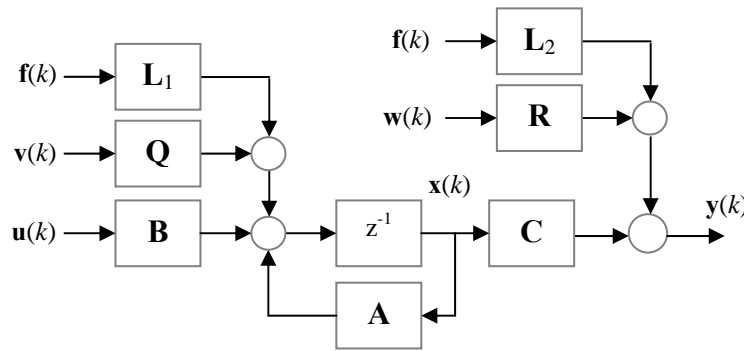


Figure 2.4 : Représentation d'état d'un processus MIMO en présence de défauts et des perturbations.

Dans le cas où $\mathbf{v}(k) = \mathbf{w}(k) = 0$, l'erreur d'estimation d'état s'exprime par :

$$\tilde{\mathbf{x}}(k+1) = (\mathbf{A} - \mathbf{H}\mathbf{C})\tilde{\mathbf{x}}(k) + \mathbf{L}_1\mathbf{f}(k) - \mathbf{H}\mathbf{L}_2\mathbf{f}(k) \quad (2.13)$$

et l'erreur de sortie prend la forme suivante :

$$\mathbf{e}(k) = \mathbf{C}\tilde{\mathbf{x}}(k) + \mathbf{L}_2\mathbf{f}(k) \quad (2.14)$$

Dans ce cas, le choix de la matrice de gain \mathbf{H} résulte d'un compromis entre stabilité de l'observateur et insensibilité de l'erreur d'estimation aux perturbations d'entrée et de sortie $\mathbf{v}(k)$ et $\mathbf{w}(k)$.

4.2.2. Observateur à entrées inconnues (UIO)

La génération de résidus avec un observateur à entrées inconnues (UIO) repose sur le principe de découplage entre les actions perturbatrices, considérées comme entrées

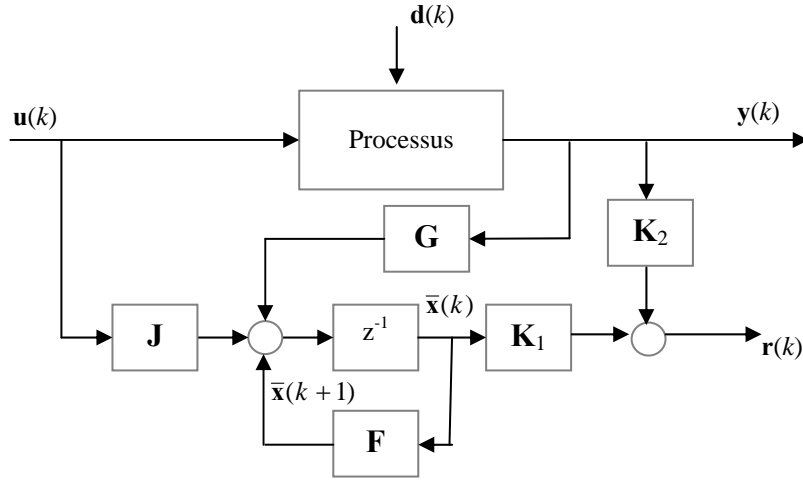


Figure 2.5 : Observateur à entrées inconnues (UIO).

inconnues dans la démarche de synthèse, et les résidus formés à partir de l'erreur d'estimation d'état. Initialement proposée par Watanabe et Himmelblau [WAT 82], puis généralisée par Frank [SIM 99] aux problèmes de diagnostic de défauts de capteurs et d'actionneurs, cette approche vise à concevoir un système de surveillance qui soit peu sensible aux incertitudes (erreurs de modélisation, perturbations) et assez sensible aux défauts. Afin d'illustrer le principe de la méthode, considérons tout d'abord le modèle d'état suivant :

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{E}_u\mathbf{d}(k) + \mathbf{L}_1\mathbf{f}_u(k) \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) \end{aligned} \quad (2.15)$$

où le vecteur $\mathbf{d}(k)$ désigne les entrées inconnues et \mathbf{E}_u la matrice de distribution associée. Le vecteur $\mathbf{f}_u(k)$ caractérise les défauts d'actionneurs. Introduisons la transformation d'état \mathbf{T} suivante :

$$\begin{aligned} \bar{\mathbf{x}}(k) &= \mathbf{T}\mathbf{x}(k) \\ \bar{\mathbf{x}}(k+1) &= \mathbf{F}\bar{\mathbf{x}}(k) + \mathbf{J}\mathbf{u}(k) + \mathbf{G}\mathbf{y}(k) \end{aligned} \quad (2.16)$$

où \mathbf{F} , \mathbf{J} et \mathbf{G} sont des matrices de dimensions appropriées à déterminer.

Dans l'espace d'état transformé, l'erreur d'estimation d'état et les résidus s'obtiennent à partir des équations suivantes :

$$\begin{aligned} \mathbf{e}(k+1) &= \bar{\mathbf{x}}(k+1) - \mathbf{T}\mathbf{x}(k+1) \\ \mathbf{r}(k) &= \mathbf{K}_1\bar{\mathbf{x}}(k) + \mathbf{K}_2\mathbf{y}(k) \end{aligned} \quad (2.17)$$

A partir des équations (2.15), (2.16) et (2.17), il est facile d'aboutir à la forme suivante de l'erreur d'estimation d'état :

$$\mathbf{e}(k+1) = \mathbf{F}\bar{\mathbf{x}}(k) + (\mathbf{J} - \mathbf{TB})\mathbf{u}(k) + \mathbf{G}\mathbf{y}(k) - \mathbf{TA}\mathbf{x}(k) - \mathbf{TE}_u\mathbf{d}(k) - \mathbf{TL}_1\mathbf{f}_u(k) \quad (2.18)$$

Pour que l'observateur suit le processus indépendamment des entrées inconnues $\mathbf{d}(k)$, il convient de choisir les matrices \mathbf{T} , \mathbf{F} , \mathbf{J} et \mathbf{G} telles que [VEN 03a] :

$$\left\{ \begin{array}{l} \mathbf{TA} - \mathbf{FT} = \mathbf{GC} \\ \mathbf{F} \text{ soit stable} \\ \mathbf{J} = \mathbf{TB} \\ \mathbf{TE}_u = 0 \\ \mathbf{K}_1\mathbf{T} + \mathbf{K}_2\mathbf{C} = 0 \end{array} \right. \quad (2.19)$$

avec $\text{rang}(\mathbf{TL}_1) = \text{rang}(\mathbf{L}_1)$

Une fois ces conditions remplies, l'erreur d'estimation d'état et les résidus seront décrits par :

$$\begin{aligned} \mathbf{e}(k+1) &= \mathbf{F}\mathbf{e}(k) - \mathbf{TL}_1\mathbf{f}_u(k) \\ \mathbf{r}(k) &= \mathbf{K}_1\mathbf{e}(k) \end{aligned} \quad (2.20)$$

Ainsi, en régime de fonctionnement normal (non défaillant), la dynamique de l'erreur d'estimation est donnée par :

$$\mathbf{e}(k+1) = \mathbf{F}\mathbf{e}(k) \quad (2.21)$$

Il est évident de noter que si \mathbf{F} est stable, $\mathbf{e}(k) \rightarrow 0$ quand $k \rightarrow \infty$. Cela revient à dire que les résidus générés par l'observateur UIO sont donc sensibles aux défauts $\mathbf{f}_u(k)$ et insensibles aux entrées inconnues $\mathbf{d}(k)$, d'où la propriété de découplage.

Notons que la démarche de synthèse d'un observateur UIO que l'on vient de décrire pour le modèle (2.15) reste toujours valable dans le cas où l'on suppose que les défauts et les entrées inconnues affectent aussi la sortie du processus surveillé. En effet, si la sortie du processus est exprimée par :

$$\mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) + \mathbf{E}_y\mathbf{d}(k) + \mathbf{L}_2\mathbf{f}_y(k) \quad (2.22)$$

où \mathbf{E}_y et \mathbf{L}_2 sont respectivement les matrices associées aux entrées inconnues $\mathbf{d}(k)$ et aux défauts de capteurs $\mathbf{f}_y(k)$, l'observateur UIO décrit par le modèle (2.16) obéira aux mêmes conditions (2.19) à lesquelles seront rajoutées les conditions suivantes [SIM 99] :

$$\begin{cases} \mathbf{G}\mathbf{E}_y = 0, & \mathbf{K}_2\mathbf{E}_y = 0 \\ \text{rang}\left(\begin{bmatrix} \mathbf{G} \\ \mathbf{K}_2 \end{bmatrix}\mathbf{L}_2\right) = \text{rang}(\mathbf{L}_2) \end{cases} \quad (2.23)$$

Ainsi, les résidus formés à partir de l'erreur d'estimation seront exprimés par :

$$\begin{aligned} \mathbf{r}(k) &= \mathbf{K}_1\mathbf{e}(k) + \mathbf{K}_2\mathbf{L}_2\mathbf{f}_y(k) \\ \mathbf{e}(k+1) &= \mathbf{F}\mathbf{e}(k) + \mathbf{G}\mathbf{L}_2\mathbf{f}_y(k) - \mathbf{T}\mathbf{L}_1\mathbf{f}_u(k) \end{aligned} \quad (2.24)$$

Il est facile de vérifier qu'en régime de fonctionnement normal, l'équation (2.24) régissant la dynamique des résidus se ramène à l'équation (2.20), justifiant, par conséquent, le découplage entre les résidus et les entrées inconnues.

4.3. Génération de résidus via l'approche espace de parité

L'objet de cette méthode concerne la génération des relations de redondance en explicitant, en même temps, leur utilisation pour la détection et la localisation des défauts de capteurs. Le principe est d'analyser la consistance des mesures et détecter la présence des défauts en cherchant à établir des relations de parité qui sont indépendantes des grandeurs inconnues mais qui restent sensibles aux défauts. D'après Gertler [GER 88; VEN 03a], cette approche repose sur l'idée d'arranger la structure du modèle du processus surveillé ou encore de créer des variantes de modèles afin de rendre possible et efficace l'isolation des défauts. C'est dans ce sens que plusieurs travaux traitant de l'application de l'approche espace de parité à différentes classes de modèles de représentation ont été menés ces dernières années. Les relations de parité dynamiques ont été introduites pour la première fois dans [WIL 76]. Une approche pour la génération des relations de redondance analytiques (RRA) à partir d'une représentation d'état a été proposée dans [CHO 84]. L'approche espace de parité a été également développée pour les modèles non linéaires et les processus représentés par les graphes orientés (cas de procédés chimiques et pétrochimique) [DID 03].

Toutes ces variantes partagent, cependant, une définition commune du vecteur de parité $\mathbf{p}(k)$ projection du vecteur des mesures $\mathbf{y}(k)$. En effet, si l'on considère le cas général d'une équation de mesure à l'instant k :

$$\mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) + \mathbf{L}_2\mathbf{f}_y(k) \quad (2.25)$$

le vecteur de parité sera défini par :

$$\mathbf{p}(k) = \mathbf{\Omega}\mathbf{y}(k) \quad (2.26)$$

où $\mathbf{\Omega} \in \mathfrak{R}^{(m-n) \times m}$ une matrice de projection possédant les propriétés suivantes :

$$\mathbf{\Omega}\mathbf{C} = 0 \quad (2.27)$$

$$\mathbf{\Omega}\mathbf{\Omega}^T = \mathbf{I}_{m-n} \quad (2.28)$$

$$\mathbf{\Omega}^T\mathbf{\Omega} = \mathbf{I}_m - \mathbf{C}(\mathbf{C}^T\mathbf{C})^{-1}\mathbf{C}^T \quad (2.29)$$

L'orthogonalité de la matrice de projection $\mathbf{\Omega}$ avec \mathbf{C} entraîne en particulier :

$$\mathbf{p}(k) = \mathbf{\Omega}\mathbf{L}_2\mathbf{f}_y(k) \quad (2.30)$$

Notons que l'expression (2.26) permet le calcul numérique du vecteur parité à partir des mesures, alors que l'expression (2.30) explique l'influence des défauts. Dans le cas idéal (absence d'erreurs de mesure et de défauts), le vecteur parité est nul ; tandis que lors d'une défaillance d'un capteur, l'amplitude du vecteur parité évolue et s'oriente dans la direction de défaillance associée au capteur concerné. Cette procédure explicite une redondance directe entre capteurs. Bien qu'elle soit utile pour la détection de défauts affectant les capteurs, elle offre peu d'intérêt pour la surveillance des actionneurs du processus.

Les travaux de Chow et Wilky [CHO 84] sur la redondance temporelle, qui lie les informations de capteurs et d'actionneurs à différents instants, ont considérablement contribué à la prise en compte de ces limitations. En effet, sur un horizon d'observation fini et à partir du modèle (2.25), les équations suivantes peuvent être établies :

$$\begin{bmatrix} \mathbf{y}(k) \\ \mathbf{y}(k+1) \\ \mathbf{y}(k+2) \\ \vdots \end{bmatrix} = \begin{bmatrix} \mathbf{C} \\ \mathbf{CA} \\ \mathbf{CA}^2 \\ \vdots \end{bmatrix} \mathbf{x}(k) + \begin{bmatrix} 0 & 0 & 0 & \dots \\ \mathbf{CB} & 0 & 0 & \dots \\ \mathbf{CAB} & \mathbf{CB} & 0 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \begin{bmatrix} \mathbf{u}(k) \\ \mathbf{u}(k+1) \\ \mathbf{u}(k+2) \\ \vdots \end{bmatrix} + \begin{bmatrix} \mathbf{L}_2 & 0 & 0 & \dots \\ \mathbf{CL}_1 & \mathbf{L}_2 & 0 & \dots \\ \mathbf{CAL}_1 & \mathbf{CL}_1 & \mathbf{L}_2 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \begin{bmatrix} \mathbf{f}_y(k) \\ \mathbf{f}_y(k+1) \\ \mathbf{f}_y(k+2) \\ \vdots \end{bmatrix} \quad (2.31)$$

ou encore sous une forme compacte :

$$\mathbf{Y}(k) = \mathbf{Q}_f \mathbf{x}(k) + \mathbf{R}_f \mathbf{U}(k) + \mathbf{L}_f \mathbf{F}_y(k) \quad (2.32)$$

Par conséquent, le vecteur parité généralisé (résidus) caractérisant toutes les relations existant entre les entrées et les sorties du processus s'explicite en fonction des mesures (forme de calcul) :

$$\mathbf{P}(k) = \mathbf{\Lambda}_f \mathbf{Y}(k) - \mathbf{\Lambda}_f \mathbf{R}_f \mathbf{U}(k) \quad (2.33)$$

ou en fonction des défauts (forme d'évaluation) :

$$\mathbf{P}(k) = \mathbf{\Lambda}_f \mathbf{L}_f \mathbf{F}_y(k) \quad (2.34)$$

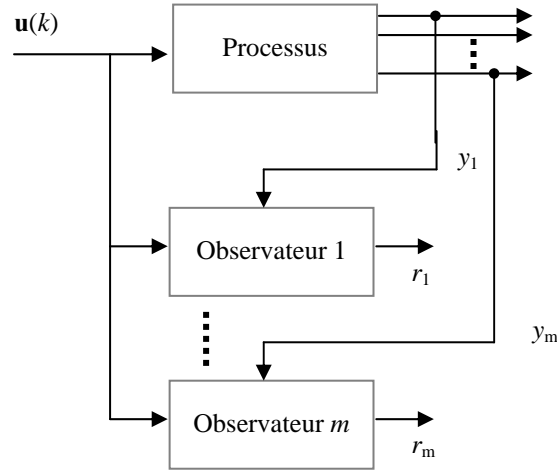


Figure 2.6 : Configuration de diagnostic DOS.

avec Λ_f une matrice de parité orthogonale à la matrice \mathbf{Q}_f .

La recherche des équations de redondance peut être affinée en recherchant tout d'abord les équations de redondance pour chaque sortie prise isolément (auto-redondance), puis les relations de redondance entre différentes sorties (inter-redondance) [DID 03]. Cette hiérarchisation peut être mise à profit dans l'étape d'isolation des défauts affectant capteurs et actionneurs.

5. Utilisation des observateurs pour la surveillance

5.1. La configuration DOS

La configuration DOS (*Dedicated Observer Scheme*), proposée initialement par Clark [CLA 78], utilise m observateurs classiques pour détecter et isoler les défauts de capteurs. En supposant l'absence de défauts d'actionneurs, la démarche de synthèse consiste à concevoir un observateur pour chacun des m capteurs de sortie arrangés de telle sorte que le i ème observateur reçoit la variable de sortie y_i depuis le i ème capteur uniquement. Le vecteur d'entrée \mathbf{u} est en revanche appliqué à l'ensemble des m observateurs comme le montre la figure 2.6. En se référant à la section 4.2.1, la dynamique de l'observateur i ($i = 1, \dots, m$) sera décrite dans l'espace d'état par :

$$\hat{\mathbf{x}}^i(k+1) = \mathbf{A}^i \hat{\mathbf{x}}^i(k) + \mathbf{B}^i \mathbf{u}(k) + \mathbf{H}^i (y_i(k) - \mathbf{C}^i \hat{\mathbf{x}}^i(k)) \quad (2.35)$$




Figure 2.7 : Configuration de diagnostic GOS.

où $\hat{\mathbf{x}}^i(k)$ est le vecteur d'état estimé à l'aide de l'observateur i , et $(\mathbf{A}^i, \mathbf{B}^i, \mathbf{C}^i)$ la réalisation MISO relative à la variable de sortie $y_i(k)$.

La matrice de gain \mathbf{H}^i de chacun des m observateurs doit être choisie de telle sorte que la matrice $(\mathbf{A}^i - \mathbf{H}^i \mathbf{C}^i)$ soit stable (à valeurs propres situées à l'intérieur du cercle unité). Ainsi, il est facile de vérifier qu'en régime de fonctionnement normal on aura :

$$\lim_{k \rightarrow \infty} r_i(k) = \lim_{k \rightarrow \infty} (y_i(k) - \mathbf{C}^i \hat{\mathbf{x}}^i(k)) = 0 \quad (2.36)$$

avec une vitesse de convergence qui dépend de la position des valeurs propres de la matrice $(\mathbf{A}^i - \mathbf{H}^i \mathbf{C}^i)$. En cas de défaillance du capteur i , $r_i(k)$ est la seule fonction qui s'écartera de zéro, ce qui conduit à une localisation évidente du défaut.

5.2. La Configuration GOS

Afin de localiser et isoler les défauts pouvant affecter les actionneurs du processus surveillé, une configuration faisant appel à r observateurs à entrées inconnues (UIO) peut être employée. Dans cette configuration, dite GOS (*Generalized Observer Scheme*), le i ème observateur reçoit tous les signaux d'entrée et de sortie du processus sauf la i ème entrée (Fig. 2.7). Ainsi, le i ème observateur pourra générer un résidu sensible aux défauts affectant toutes les entrées à l'exception de la i ème entrée. Afin

d'illustrer la démarche de synthèse, considérons le modèle (2.15) du processus surveillé. D'après la section 4.2.2, la dynamique du i ème observateur UIO est décrite par les équations suivantes :

$$\begin{aligned}\bar{\mathbf{x}}^i(k) &= \mathbf{T}^i \mathbf{x}^i(k) \\ \bar{\mathbf{x}}^i(k+1) &= \mathbf{F}^i \bar{\mathbf{x}}^i(k) + \mathbf{J}^i \mathbf{u}(k) + \mathbf{G}^i \mathbf{y}(k) \\ \mathbf{r}^i(k) &= \mathbf{K}_1^i \bar{\mathbf{x}}^i(k) + \mathbf{K}_2^i \mathbf{y}(k)\end{aligned}\quad (2.37)$$

L'erreur d'estimation prend la forme :

$$\mathbf{e}^i(k+1) = \mathbf{F}^i \mathbf{e}^i(k) + (\mathbf{F}^i \mathbf{T}^i - \mathbf{T}^i \mathbf{A} + \mathbf{G}^i \mathbf{C}) \mathbf{x}(k) + (\mathbf{J}^i - \mathbf{T}^i \mathbf{B}) \mathbf{u}(k) - \mathbf{T}^i \mathbf{E} \mathbf{d}(k) - \mathbf{T}^i \mathbf{L}_1 \mathbf{f}_u(k) \quad (2.38)$$

et le vecteur résiduel s'exprime par :

$$\mathbf{r}^i(k) = \mathbf{K}_1^i \mathbf{e}^i(k) + (\mathbf{K}_1^i \mathbf{T}^i + \mathbf{K}_2^i \mathbf{C}) \mathbf{x}(k) \quad (2.39)$$

Remarquons que si l'on choisit les matrices \mathbf{T}^i , \mathbf{F}^i , \mathbf{J}^i et \mathbf{G}^i , \mathbf{K}_1^i et \mathbf{K}_2^i ($i = 1, \dots, r$) telles que :

$$\begin{cases} \mathbf{T}^i \mathbf{A} - \mathbf{F}^i \mathbf{T}^i = \mathbf{G}^i \mathbf{C} \\ \mathbf{J}^i = \mathbf{T}^i \mathbf{B} \\ \mathbf{T}^i \mathbf{E} = 0 \\ \mathbf{K}_1^i \mathbf{T}^i + \mathbf{K}_2^i \mathbf{C} = 0 \end{cases} \quad (2.40)$$

les équations (2.38) et (2.39) deviennent :

$$\begin{aligned}\mathbf{e}^i(k+1) &= \mathbf{F}^i \mathbf{e}^i(k) - \mathbf{T}^i \mathbf{L}_1 \mathbf{f}_u(k) \\ \mathbf{r}^i(k) &= \mathbf{K}_1^i \mathbf{e}^i(k)\end{aligned}\quad (2.41)$$

Ces deux dernières équations traduisent le fait que le i ème vecteur résiduel $\mathbf{r}^i(k) \rightarrow 0$ quand $k \rightarrow \infty$ avec une vitesse de convergence qui dépend de la position des valeurs propres de la matrice \mathbf{F}^i à l'intérieur du cercle unité.

Lorsqu'un défaut affecte la i ème entrée, le i ème résidu demeure alors insensible à ce défaut, tandis que les résidus issus des $(r-1)$ observateurs UIO seront tous affectés, permettant par conséquent une localisation parfaite du défaut. Une approche pour le choix de la matrice de transformation \mathbf{T}^i ainsi que des matrices satisfaisant les conditions (2.40) est présentée dans [SIM 03].

6. Détection de changements et génération de symptômes analytiques

Les résidus de détection générés à l'aide d'une méthode quelconque de surveillance à base de modèles sont généralement soumis aux effets des bruits de mesures, des perturbations externes agissant sur le processus surveillé, ainsi qu'à l'effet d'autres signaux mal connus. Il est donc tout à fait évident de les considérer et de les traiter en tant que variables stochastiques pour optimiser la prise de décision. En procédant ainsi, un résidu $r_i(k)$, ($i = 1, \dots, q$), se caractérise alors par une moyenne \bar{v}_i et une variance $\bar{\sigma}_i^2$ [ISE 97] :

$$\bar{v}_i = E\{r_i(k)\}; \quad \bar{\sigma}_i^2 = E\{[r_i(k) - \bar{v}_i]^2\} \quad (2.42)$$

estimées en régime de fonctionnement sain, où $E\{\bullet\}$ désigne l'espérance mathématique. Le problème de la détection et du diagnostic de défauts se transforme alors en un problème de détection et de diagnostic de changements dans la moyenne et la variance des résidus. Ces changements sont évalués par rapport aux valeurs obtenues en mode de fonctionnement sain, *i.e.*

$$\Delta v_i = E\{r_i(k) - \bar{v}_i\}; \quad \Delta \sigma_i = E\{\sigma_i(k) - \bar{\sigma}_i\} \quad (2.43)$$

pour $k > k_a$, où k_a est l'instant d'alarme.

Une logique de décision à seuils peut intervenir par la suite pour choisir entre l'hypothèse sans défauts et l'hypothèse des défauts. Des méthodes de détection de changements tels que la méthode de somme cumulée, le test du rapport de vraisemblance généralisé (GLR) ou encore le seuillage adaptatif peuvent être envisagées pour améliorer la logique de décision binaire [ISE 97; BAS 93; BLA 03].

7. Conservatisme des méthodes de surveillance à base de modèles

Bien que les techniques de génération de résidus utilisant le concept de redondance analytique soient intéressantes du point de vue détection et isolation de défauts, l'inévitable problème d'incertitudes dues aux erreurs de modèle, aux imprécisions et aux bruits de mesure demeure cependant intensivement posé. Parmi les causes de conservatisme des méthodes de surveillance à base de modèles, on peut rappeler que toutes les approches examinées dans ce chapitre suppose la disponibilité d'un modèle mathématique suffisamment précis et représentatif du processus surveillé. L'efficacité et la robustesse de l'algorithme de surveillance sont étroitement liées à la qualité du modèle utilisé. En fait, si l'on arrive à développer des modèles suffisamment précis pour les systèmes mécaniques, il n'en est pas du tout le cas pour les processus chimiques, pétrochimiques ou thermiques en raison de la diversité des non linéarités que l'on peut rencontrer.

Afin d'assouplir cette contrainte, certains travaux ont tenté de minimiser l'effet des incertitudes liées à la modélisation en employant des critères de sensibilité aux défauts. D'autres envisagent des formalismes transformant le problème de robustesse des algorithmes de surveillance en un problème d'optimisation. La méthode de détection de défauts avec des observateurs à entrées inconnues (UIO), abordée dans la section 4.2.2, est justement l'une des alternatives proposées dans ce sens. Quoique intéressante d'un point de vue méthodologique, elle laisse cependant retenir un certain nombre de limitations, en particulier :

- pour certaines classes de systèmes, les conditions (2.19) ne peuvent pas être simultanément remplies,
- dans le cas d'incertitudes non structurées (dues aux erreurs de modèle, à la linéarisation ou encore à la variation de paramètres), l'utilisation de l'approche UIO s'avère difficile, voire impossible. Dans ce cas précis, les matrices de distribution E_u et E_y ne sont généralement pas connues [SIM 99],
- il n'existe pas de méthodes systématiques servant à la détermination de la matrice de transformation T . De plus, pour certaines classes de processus, cette matrice n'existe pas.

Enfin, il convient de noter que l'extension des méthodes de surveillance présentées dans les sections précédentes à des processus décrits par des modèles non linéaires a été aussi abordée dans plusieurs travaux [FRA 97a; SEL 91; ALC 98]. Pour certaines classes de processus non linéaires, l'application de ces méthodes est systématique, pour les classes les plus rencontrées en pratique, la transformation des modèles devient une étape nécessaire [ZHI 94a; ZHI 94b]. Néanmoins, l'existence de ces lois de transformation n'est pas toujours garantie [FRA 97a], ce qui limite la mise en œuvre effective de ces approches en milieu industriel.

8. Intégration de l'intelligence artificielle à la surveillance

Les méthodes de surveillance que nous venons d'exposer dans ce qui précède nécessitent une modélisation précise du processus surveillé ou à la limite suffisamment tolérante aux incertitudes. Une exigence qui devient de plus en plus sévère lorsque la dynamique du processus en question est complexe ou encore difficile, voire impossible à décrire par des équations analytiques. Les systèmes experts à base de connaissances manipulés dans le domaine de l'intelligence artificielle ont été justement envisagés afin d'apporter des solutions aux problèmes de surveillance et de supervision de processus complexes. Dans ce contexte, les données traitées sont de nature extrêmement variées : imprécises (bruit de mesure), incomplètes (défauts de capteurs), non homogènes (logiques, analogiques, qualitatives) et temporelles. La diversité et la complexité de cette quantité d'informations font douter de la seule validité des modèles quantitatifs, surtout en cas de défaillance.

Il est important de noter que l'intelligence artificielle n'est guère vue comme un substitut aux méthodes de surveillance conventionnelles. Pour le besoin de détection et d'isolation de défauts, la logique floue et les réseaux de neurones artificiels peuvent être efficacement utilisés pour élaborer des modèles de comportement de processus complexes qui seront ensuite utilisés par les méthodes de surveillance exposées dans les sections précédentes. A titre d'exemple, les modèles établis à l'aide de la logique floue, dits aussi modèles à base de connaissances flous, sont en général assez flexibles et peuvent caractériser au mieux les diverses non linéarités rencontrées en pratique. Aussi, la logique floue offre la possibilité de développer des modèles non linéaires que l'on peut assimiler à des multimodèles et qui peuvent être exploités de façon systématique par les techniques de surveillance basées sur l'utilisation de modèles. L'approche multimodèle est très intéressante car elle permet de surmonter les difficultés liées à la variation du point de fonctionnement dans les processus non linéaires. Une approche multimodèle se basant sur l'utilisation de systèmes à base de connaissances flous fera l'objet des chapitres 3 et 4.

Les techniques de l'intelligence artificielle sont également employées pour résoudre le problème de diagnostic et de prise de décision. De manière duale, les méthodes de surveillance utilisant des modèles à base de connaissances peuvent générer des indicateurs qui pourront ensuite être classés à l'aide de méthodes de classification et de reconnaissance de formes de façon à émettre un diagnostic. Dans ce sens, les réseaux de neurones sont utilisés pour identifier les défauts à partir des mesures entrées-sorties. Leur efficacité provient de leur capacité d'approximation universelle et de leur robustesse vis-à-vis des bruits de mesure. Notons que les techniques de l'intelligence artificielle sont le plus souvent employées de manière conjointe avec les méthodes de surveillance conventionnelles ; une démarche de conception qui a nettement contribué à l'amélioration de la robustesse des algorithmes de surveillance.

9. Conclusions

Dans ce chapitre, les principales méthodes de surveillance à base de modèles sont étudiées. Le problème de surveillance est posé suivant un formalisme unifié impliquant la description mathématique du processus surveillé et la méthode de dérivation du système de génération des résidus. Dans ce formalisme, la génération de résidus constitue l'ingrédient de base d'une démarche de surveillance basée sur l'utilisation de modèles. La structure du générateur de résidus est propre à la méthode employée. L'utilisation de multiples observateurs pour le besoin de détection et d'isolation de défauts de capteurs et d'actionneurs est aussi traitée. Dans ce sens, deux configurations différentes sont considérées : la configuration DOS basée sur des observateurs de type Luenberger et la configuration GOS employant des observateurs à entrées inconnues (UIO). Réussir une tâche de diagnostic dépend fondamentalement de la qualité du modèle manipulé. C'est la raison pour laquelle les méthodes à base de modèles examinées dans ce chapitre sont plus ou moins conservatives, d'autant plus qu'elles se fondent sur un modèle linéaire du processus.

Pour assouplir cette contrainte, les techniques de l'intelligence artificielle sont évoquées pour être introduites comme une alternative qui doit apporter un plus aux méthodes conventionnelles de surveillance. Parmi ces techniques, citons la logique floue à laquelle nous allons nous intéresser dans les chapitres qui suivent.

Chapitre 3

Identification de systèmes flous en vue de la surveillance

1. Introduction

Dans une démarche de conception de systèmes de régulation et de surveillance, on est souvent contraint de passer par une étape de modélisation, tout au moins avec les méthodes basées sur des modèles. Pour les systèmes faisant intervenir des phénomènes bien connus, les lois physiques sont utilisées pour la modélisation, telle que les lois de conservation d'énergie et de matière ou encore les lois de Newton et d'Ohm. En pratique, les procédés industriels font souvent intervenir des phénomènes physiques mal connus ou trop complexes pour que les équations physiques puissent être raisonnablement établies. Néanmoins, de tels procédés sont souvent équipés d'un grand nombre de capteurs qui génèrent des signaux reflétant, à tout instant, le fonctionnement du procédé. Cette abondance de signaux peut être exploitée pour compenser le manque de connaissance physique, en supposant une structure de modèle assez générale et flexible. Un modèle ainsi obtenu est appelé *modèle boîte-noire* [ZHA 99].

Les procédés industriels ont plus ou moins des propriétés non linéaires, un modèle linéaire n'en est qu'une approximation. Pour le besoin de surveillance, une telle approximation a moins de chance d'être satisfaisante, car la surveillance doit être robuste au changement du point de fonctionnement, ce qui signifie que le modèle utilisé doit avoir un aspect plus global en couvrant une zone de fonctionnement assez large. Une telle exigence explique bien l'intérêt grandissant que réservent beaucoup de chercheurs à la manipulation de modèles non linéaires dans la conception d'algorithmes de surveillance. Les modèles non linéaires les plus récents que nous pouvons qualifier de boîtes-noires sont sans doute ceux qui ont été développés depuis les années 80, notamment les modèles flous, les réseaux de neurones et les ondelettes.

Dans la section 2, nous résumons un formalisme unifié de modèles non linéaires boîtes-noires, avant de faire quelques remarques sur les modèles flous de processus dans la section 3. Le problème particulier d'identification de modèles flous est considéré dans la section 4. Dans la section 5, nous revenons sur l'utilisation des modèles flous pour la détection et le diagnostic de défauts dans les processus dynamiques.

2. Identification de modèles non linéaires boîtes-noires

L'identification boîte-noire non linéaire est une tâche plutôt complexe en raison de la diversité des non linéarités pouvant caractériser un procédé industriel. L'idée consiste à utiliser des structures de modèles assez flexibles pour obtenir de bonnes approximations des relations non linéaires les plus courantes. Le choix de ces structures est en lui-même un problème clef, le recours à des connaissances très probablement disponibles sur le procédé constitue une des issues les plus recommandées dans ce sens. De nombreux domaines de recherche sont concernés par ce sujet, notamment la régression non paramétrique [STO 82; SIL 86], les modèles flous [CAO 97a; JAN 95; YEN 98], les réseaux de neurones [REN 95; HEY 97] et les ondelettes [ZHA 99]. Dans la suite, un formalisme unifié de modèles boîtes-noires est sommairement présenté.

2.1. Modèles dynamiques à mémoire finie

Lorsqu'il s'agit de mettre en évidence la dynamique d'un système physique, on est souvent amené à exprimer sa sortie y à l'instant courant k en fonction de l'entrée actuelle et du passé de l'entrée et de la sortie. Cette dépendance définit un modèle dynamique de la forme :

$$y(k) = f(\varphi(k), \boldsymbol{\theta}) \quad (3.1)$$

où $f(\bullet)$ est une fonction non linéaire paramétrée par un vecteur de paramètres $\boldsymbol{\theta}$, et φ un vecteur de dimension finie, appelé le vecteur de régresseurs. L'identification du modèle (3.1) est généralement résolue en deux étapes : identification de la structure du modèle, *i.e.* $\varphi(k)$ et f , puis estimation des paramètres $\boldsymbol{\theta}$.

2.1.1. Régresseurs

La majorité des régresseurs utilisés dans les modèles boîtes-noires non linéaires sont aussi utilisés dans les modèles linéaires. Pour présenter les exemples typiques, considérons un système MISO avec les entrées $\mathbf{u} \in \mathcal{R}^r$ et la sortie y . Notons la sortie du modèle par prédiction :

$$\begin{aligned} \hat{y}(\mathbf{u}, y, \boldsymbol{\theta}) &= f(\varphi, \boldsymbol{\theta}) \\ &= f(\mathbf{u}, y, \boldsymbol{\theta}) \end{aligned} \quad (3.2)$$

et la sortie du modèle par simulation :

$$\hat{y}(\mathbf{u}, \boldsymbol{\theta}) = f(\mathbf{u}, \hat{y}, \boldsymbol{\theta}) \quad (3.3)$$

Avec ces notations, nous citons dans la suite quelques exemples de régresseurs.

- **Réponse impulsionnelle finie (FIR)** : les régresseurs sont uniquement composés de $\mathbf{u}(k-i)$ avec $i = 1, 2, \dots$.
- **Auto-régressif avec entrée exogène (ARX)** : les régresseurs sont composés de $\mathbf{u}(k-i)$ et $y(k-i)$ avec $i = 1, 2, \dots, i.e.$

$$\varphi(k) = [u_1(k-1), \dots, u_1(k-n_{u1}), \dots, u_r(k-1), \dots, u_r(k-n_{ur}), \dots, y(k-1), \dots, y(k-n_y)]^T \quad (3.4)$$

où n_{u1}, \dots, n_{ur} et n_y des entiers définissant l'ordre du modèle.

- **Auto-régressif à moyenne mobile avec entrée exogène (ARMAX)** : les régresseurs sont composés de $\mathbf{u}(k-i)$, $y(k-i)$ et $e(k-i) = y(k-i) - \hat{y}(\mathbf{u}, y, \boldsymbol{\theta})$.
- **Erreur de sortie (OE)** : les régresseurs sont composés de $\mathbf{u}(k-i)$ et $\hat{y}(\mathbf{u}, \boldsymbol{\theta})$.
- **Entrée et sortie pré-filtrées** : les régresseurs sont composés de $\mathbf{u}(k-i)$ et $y(k-i)$ filtrés par des filtres linéaires.

2.1.2. Fonctions non linéaires

Après avoir choisi les régresseurs, il faut définir une famille de fonctions non linéaires pour exprimer la relation entre les régresseurs et la sortie du modèle. Les familles de fonctions utilisées en pratique sont sous forme d'expansions :

$$f(\varphi(k)) = \sum_i w_i \Phi_i(\varphi(k)) \quad (3.5)$$

avec un ensemble de fonctions de base Φ_i . Le vecteur $\boldsymbol{\theta}$ représente l'ensemble des w_i et éventuellement des paramètres de Φ_i . Des exemples de fonctions non linéaires utilisées en identification boîte-noire sont donnés ci-après.

- **Série de Fourier** : Les fonctions de base sont formées de fonctions sinusoïdes, principalement utilisées en mono-dimensionnel, *i.e.*, $\varphi(k) \in \mathfrak{R}$.

- **Réseau de neurones perceptron multi-couches** : Le réseau de neurones se présente par définition sous la forme (3.5). Le neurone est caractérisé par des poids synaptiques et une fonction de base, appelée aussi fonction d'activation.
- **Réseau de neurones à base radiale** : Dans ce cas, les fonctions de base sont des fonctions radiales, typiquement la fonction gaussienne, translatées dans l'espace du vecteur de régression φ .
- **Modèle Flou** : Un modèle construit à partir d'une base de règles floues se présente également sous la forme (3.5). Les fonctions de base d'un modèle flou sont par définition les fonctions d'appartenance des ensembles flous.

2.1.3. Estimation de paramètres

Après avoir choisi la structure du modèle, *i.e.* f et $\varphi(k)$, il faut estimer le vecteur des paramètres θ de dimension choisie à partir d'un ensemble d'observations entrées-sorties :

$$\mathcal{Z}_e = \{(\mathbf{u}(k), y(k)) : k = 1, 2, \dots, N\} \quad (3.6)$$

L'estimation des paramètres θ est généralement réalisée par la minimisation d'un critère de la forme :

$$E(\theta, \mathcal{Z}_e) = \frac{1}{N} \sum_{k=1}^N \|y(k) - f(\varphi(k), \theta)\|^2 \quad (3.7)$$

Les méthodes classiques d'optimisation utilisent le gradient analytique de $E(\theta, \mathcal{Z}_e)$, ce qui nécessite la manipulation de dérivées partielles. Récemment, des mécanismes beaucoup plus puissants sont développés pour le calcul de ces dérivées, notamment l'algorithme de rétro-propagation qui a joué un rôle important dans l'apprentissage des systèmes neuro-flous [YAG 94; JAN 95; PED 93].

Quand la fonction $f(\varphi(k), \theta)$ est linéaire en θ , le critère $E(\theta, \mathcal{Z}_e)$ est quadratique en θ avec la norme euclidienne. Dans ce cas, la minimisation de $E(\theta, \mathcal{Z}_e)$ peut être réalisée à l'aide de la technique des moindres carrés ordinaires ou récurrents.

3. Modèles Flous de processus

Depuis les travaux de Zadeh [ZAD 73], la théorie des ensembles flous est rapidement devenue populaire marquant, par voie de conséquence, un réel succès en modélisation et commande de processus industriels complexes. Dans le cas de la modélisation, la capacité de l'approximation universelle d'un modèle flou [YIN 98b] est

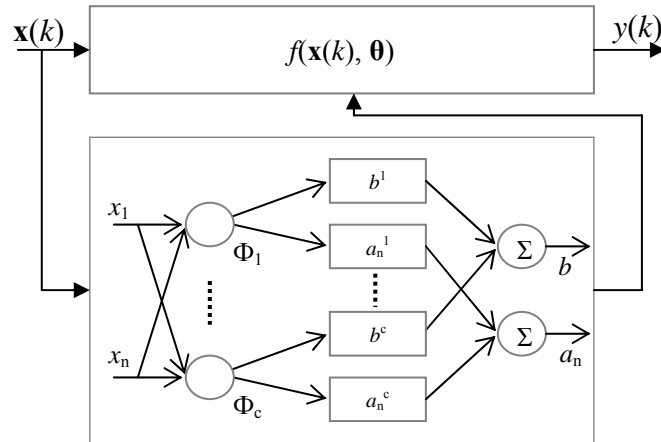


Figure 3.1 : Linéarisation dynamique d'un modèle flou TS.

la base de presque toutes les recherches théoriques et de leurs applications. De nombreux chercheurs se sont intéressés à cette notion pour donner une justification théorique aux succès rencontrés au niveau des applications [JOH 00; BAL 00; DRI 96; JAM 93]. Dans cette section, nous faisons quelques remarques sur les modèles flous de processus en les situant dans le contexte concerné. La présentation suivante est principalement inspirée des travaux de Yager et Filev [YAG 94].

3.1. Classification des modèles flous

Dans la littérature, on peut dénombrer plusieurs formes de modèles flous répartis généralement en deux principales classes : le modèle flou linguistique ou de Mamdani et le modèle flou de Takagi-Sugeno (TS). La première classe étant une forme de représentation purement qualitative, employant des ensembles flous et des règles conditionnelles de type IF-THEN. Elle a l'avantage de permettre l'intégration du langage naturel en modélisation tout en préservant l'aspect vague de l'information. En contrepartie, il n'est pas possible d'intégrer les connaissances quantitatives dans la structure d'un modèle linguistique, un type de connaissance d'une utilité majeure pour la modélisation des processus régis par les lois de conservation de masse et d'énergie.

La deuxième classe de modèles flous est en fait une combinaison de modèles flous et non flous, établie de façon à permettre de manipuler conjointement les connaissances qualitatives et quantitatives disponibles sur le processus à modéliser. C'est la classe de modèles à laquelle nous allons nous intéresser dans la suite de ce chapitre.

3.2. Structure d'un modèle flou TS

Les modèles flous TS représentent les systèmes non linéaires sous forme d'une interpolation entre des modèles linéaires ou non linéaires locaux. Dans le cas linéaire, chaque modèle local est un système dynamique LTI valide autour d'un point de fonctionnement donné. Les modèles flous TS réalisent une partition floue de l'espace caractéristique ou de décision¹ :

$$\mathcal{Z} = \{(\mathbf{x}(k), y(k)) : k = 1, 2, \dots, N\} \quad (3.8)$$

Les zones de fonctionnement sont définies en termes de propositions sur les variables caractéristiques. La forme généralement retenue d'un modèle flou TS est [TAK 85] :

$$\begin{aligned} R^i : & \text{ If } x_1 \text{ is } A_1^i \text{ and } x_2 \text{ is } A_2^i \text{ and } \dots \text{ and } x_n \text{ is } A_n^i \\ & \text{ Then } y^i = a_1^i x_1 + \dots + a_n^i x_n + b^i \quad (1 \leq i \leq c), \end{aligned} \quad (3.9)$$

où $\mathbf{x}(k) = [x_1 \ x_2 \ \dots \ x_n]^T \subseteq \varphi(k)$ est le vecteur des variables caractéristiques ou de décision, A_j^i ($1 \leq i \leq c$, $1 \leq j \leq n$) sont des ensembles flous, et c est le nombre de règles. Dans la conclusion de chaque règle floue un modèle linéaire à paramètres constants est employé.

En prenant l'opérateur produit comme opérateur de conjonction, la sortie y du modèle flou résultant de l'inférence des c règles est donnée par :

$$y(k) = \sum_{i=1}^c (a_1^i x_1 + \dots + a_n^i x_n + b^i) \Phi_i(\mathbf{x}(k)) \quad (3.10)$$

La fonction de base $\Phi_i(\mathbf{x}(k))$ coïncide exactement avec le degré d'activation normalisé de la règle R^i . Celle-ci est exprimée par :

$$\Phi_i(\mathbf{x}) = \frac{\mu_i}{\sum_{l=1}^c \mu_l} = \frac{\prod_{j=1}^n \mu_{A_j^i}(x_j)}{\sum_{l=1}^c \prod_{j=1}^n \mu_{A_j^l}(x_j)} \quad (3.11)$$

avec $\mu_{A_j^i}(x_j) : \mathcal{R} \rightarrow [0, 1]$, la fonction d'appartenance de la variable x_j à l'ensemble flou A_j^i .

¹ C'est l'espace caractérisé par l'ensemble des variables caractéristiques (ou de décision) qui peuvent être des variables de sortie mesurables et/ou d'entrée.

Pour compléter l'analyse de la structure du modèle (3.10), réécrivons la sortie y sous la forme suivante :

$$\begin{aligned} y(k) &= \left(\sum_{i=1}^c b^i \Phi_i(\mathbf{x}) \right) + \left(\sum_{i=1}^c a_1^i \Phi_i(\mathbf{x}) \right) x_1(k) + \dots + \left(\sum_{i=1}^c a_n^i \Phi_i(\mathbf{x}) \right) x_n(k) \\ &= b(\mathbf{x}(k)) + a_1(\mathbf{x}(k))x_1(k) + \dots + a_n(\mathbf{x}(k))x_n(k) \end{aligned} \quad (3.12)$$

La relation (3.12) décrit clairement un modèle pseudo-linéaire à paramètres variant (LPV). Les paramètres dépendent des régresseurs, donc de la condition des règles, ce qui reflète bien la non linéarité du modèle. D'après Fischer et Nelles [BAL 99], l'expression (3.12) est perçue comme étant une linéarisation dynamique de la fonction non linéaire $f(\bullet)$. La figure 3.1 illustre ce concept.

Notons que le modèle flou TS (3.12) coïncide exactement avec un réseau de neurones à base radiale en choisissant des fonctions de base gaussiennes dans les prémisses des règles [FIN 00]. Cette équivalence lui confère la propriété de reconversion en plus de sa capacité d'approximation universelle, démontrée dans le cas où l'on prend $\mathbf{x}(k) = \varphi(k)$ [CAO 97a].

3.3. Méthodes d'obtention des modèles flous TS

Comme nous venons de le souligner dans la section 3.2, le modèle flou TS a, en pratique, plus de rapport avec les multimodèles qu'avec les modèles linguistiques de Mamdani. D'ailleurs, c'est pour cette raison qu'il se trouve le plus convoité par les applications industrielles. Partant de ce principe, trois méthodes sont offertes pour l'obtention d'un modèle flou TS : par identification, par linéarisation dynamique ou par transformation polytopique convexe. Dans la première situation, à partir de données sur les entrées et les sorties, on peut identifier les régimes de fonctionnement locaux. Dans la deuxième et la troisième situation, on suppose disposer d'un modèle mathématique non linéaire.

3.3.1. Par linéarisation dynamique

Dans ce cas, on suppose disposer d'un modèle mathématique non linéaire du processus physique qu'on linéarise autours de différents points de fonctionnement judicieusement choisis. Ce choix ne doit en aucun cas être arbitrairement posé ni guidé par le seul besoin à la recherche d'une représentation simplifiée. L'interprétabilité du modèle flou TS devrait en revanche constituer l'objectif majeur de toute démarche basée sur la linéarisation.

Pour illustrer ce concept, considérons le système non linéaire continu suivant :

$$\dot{\mathbf{x}}(t) = F(\mathbf{x}(t), \mathbf{u}(t)) \quad (3.13)$$

avec $F(\bullet) \in C^1$, $\mathbf{x}(t) \in \mathfrak{R}^n$ et $\mathbf{u}(t) \in \mathfrak{R}^r$. Nous utiliserons \mathbf{x} dans cette section pour désigner le vecteur d'état afin de respecter les traditions en représentation d'état. La linéarisation dynamique du système (3.13) autour d'un point de fonctionnement variant $(\mathbf{x}^0, \mathbf{u}^0)$ sur une trajectoire continue $(\mathbf{x}^0(t), \mathbf{u}^0(t)) \subset \mathfrak{R}^n \times \mathfrak{R}^r$ aboutit à un système linéaire à temps variant (LTV) de la forme :

$$\begin{aligned} \dot{\mathbf{x}}(t) = & F(\mathbf{x}^0(t), \mathbf{u}^0(t)) + \frac{\partial F}{\partial \mathbf{x}}(\mathbf{x}^0(t), \mathbf{u}^0(t))(\mathbf{x}(t) - \mathbf{x}^0(t)) \\ & + \frac{\partial F}{\partial \mathbf{u}}(\mathbf{x}^0(t), \mathbf{u}^0(t))(\mathbf{u}(t) - \mathbf{u}^0(t)) \end{aligned} \quad (3.14)$$

Afin d'approximer le modèle non linéaire (3.13) par un modèle flou TS "interprétable", on considère c modèles locaux issus d'une linéarisation autour de c points de fonctionnement $\{(\mathbf{x}^i, \mathbf{u}^i), i = 1, \dots, c\} \subset \mathfrak{R}^n \times \mathfrak{R}^r$. L'inférence de l'ensemble des c règles floues conduit au modèle non linéaire suivant :

$$\begin{aligned} \dot{\mathbf{x}}(t) = & \sum_{i=1}^c [F(\mathbf{x}^i, \mathbf{u}^i) + \frac{\partial F}{\partial \mathbf{x}}(\mathbf{x}^i, \mathbf{u}^i)(\mathbf{x}(t) - \mathbf{x}^i) \\ & + \frac{\partial F}{\partial \mathbf{u}}(\mathbf{x}^i, \mathbf{u}^i)(\mathbf{u}(t) - \mathbf{u}^i)] \Phi_i(\mathbf{x}(t), \mathbf{u}(t)) \end{aligned} \quad (3.15)$$

Remarquons que le modèle flou (3.15) est établi à partir de la représentation d'état du système (3.13). Ainsi, on peut espérer étendre au cas non linéaire les techniques d'analyse appliquées aux systèmes linéaires. Dans ce sens, la tâche de synthèse de lois de commande ou de multi-observateurs devient plutôt aisée. Cependant, les réserves sur les garanties de stabilité demeurent posées, mais il est possible de les surmonter dans des contextes bien précis [CHA 02]. L'application de cette approche à un processus benchmark est l'objet de notre article [HAB 03].

3.3.2. Par identification

Les modèles flous sont identifiés à partir des données sur les entrées et sur les sorties d'un processus autour de différents points de fonctionnement. Indépendamment du type de modèle choisi, cette identification requiert la recherche d'une structure optimale, l'estimation des paramètres et la validation du modèle final. Les travaux de recherche menés dans ce sens adoptent généralement deux principales orientations : dans la première, en supposant connaître la structure du modèle à identifier, notamment le nombre de règles floues, la forme des fonctions d'appartenance et l'ordre des modèles locaux figurant dans la conclusion de chaque règle, une procédure d'optimisation est

utilisée pour optimiser davantage les paramètres du modèle. Dans le cas où l'on procède par rétro-propagation pour minimiser l'erreur quadratique d'approximation, on aboutit à un modèle combinant les propriétés fondamentales des systèmes flous et des réseaux de neurones artificiels [YAG 94]. Toutefois, les avantages de cette approche ne nous empêchent pas de rappeler ses principales limitations, en particulier :

- cette méthode d'optimisation dépend essentiellement du choix des paramètres initiaux ;
- les propriétés de généralisation du modèle flou obtenu sont généralement faibles ;
- la procédure d'optimisation neuro-floue pourrait détruire le sens de la base des règles floues (validité des modèles locaux), ce qui rend difficile l'interprétation du modèle flou optimisé.

La deuxième approche pour construire un modèle flou TS qui approche une fonction non linéaire $f(\bullet)$ à partir de l'ensemble \mathcal{Z} est de considérer le principe de groupement de données, dit *clustering*. La structure et les paramètres du modèle flou sont générés de manière systématique à partir de ces données. Vu sa particularité, cette approche a suscité l'intérêt de plusieurs chercheurs qui ont pu développer, depuis quelques années, différents types d'algorithmes de clustering appliqués non seulement à l'identification des systèmes flous mais aussi à la commande, à la surveillance, à l'optimisation et à la reconnaissance de formes, pour ne citer que quelques domaines.

4. Identification des modèles flous TS par la méthode du clustering

L'idée principale derrière l'utilisation du principe de groupement de données en identification de processus dynamiques, que nous désignons par *clustering* le long de cette thèse, repose sur le fait que la dynamique de tout système non linéaire forme une hypersurface dans \mathcal{Z} . La technique du clustering envisage d'approcher cette hypersurface par un nombre prédéfini (ou à estimer) d'hyperplans. Le problème d'identification dont il est question est transformé en un problème d'optimisation non linéaire et est résolu à l'aide de méthodes appropriées. Dans ce qui suit, nous présentons les principaux concepts de ce formalisme.

4.1. Principe du clustering

Considérons tout d'abord un ensemble d'observations entrées-sorties représenté par une matrice de données $\mathbf{Z}^T = [\mathbf{X} \mathbf{y}]$ de dimension $((n+1) \times N)$, construite à partir des données de régression $\mathbf{X} = [\mathbf{x}_1^T \mathbf{x}_2^T \dots \mathbf{x}_N^T]^T$ et celles de sortie $\mathbf{y} = [y_1 \ y_2 \dots y_N]^T$, et un c -uplet de prototypes $\mathbf{P} = (P_1, P_2, \dots, P_c)$ caractérisant chacun un des c clusters recherchés ($1 < c < N$). Remarquons qu'un élément $\mathbf{z}_k = [x_{1k} \ x_{2k} \ \dots \ x_{nk}, y_k]^T = [\mathbf{x}_k^T, y_k]^T$ de $\mathbf{Z} \in \mathfrak{R}^{(n+1) \times N}$ est un vecteur colonne de dimension $(n+1)$.

Le problème général du clustering consiste à partitionner de manière optimale l'ensemble de données \mathbf{Z} en c sous-ensembles (clusters) pouvant chevaucher entre eux. L'élément \mathbf{z}_k se voit donc attribué un degré d'appartenance au cluster P_i variant entre 0 et 1. Le groupement de ces éléments s'effectue sur la base d'un critère de similitude exprimé en termes d'une mesure appropriée de distance qui dépend des prototypes choisis. Le problème d'optimisation non linéaire associé s'énonce comme suit :

$$\underset{(\mathbf{U}, \mathbf{P})}{\text{minimiser}} J(\mathbf{Z}; \mathbf{U}, \mathbf{P}) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^\delta d^2(\mathbf{z}_k, P_i) \quad (3.16)$$

$$\text{sous les contraintes} \quad \begin{cases} \sum_{i=1}^c \mu_{ik} = 1, \forall k \\ 0 < \sum_{k=1}^N \mu_{ik} < 1, \forall i \end{cases} \quad (3.17)$$

où $\mathbf{U} = [\mu_{ik}]_{c \times N}$, $\mu_{ik} \in [0, 1]$, est la matrice de partition floue composée des degrés d'appartenance des observations \mathbf{z}_k aux clusters P_i , et $d(\mathbf{z}_k, P_i)$ la distance entre le vecteur \mathbf{z}_k et le cluster P_i . Le paramètre $\delta \in [1, \infty]$ caractérise le degré de flou des clusters (*fuzziness index*). Dans le cas où $\delta \rightarrow 1$, les clusters seront assimilés à des sous-ensembles classiques, *i.e.* $\mu_{ik} \in \{0, 1\}$, et si $\delta \rightarrow \infty$, on aura $\mu_{ik} \rightarrow 1/c$.

Plusieurs algorithmes de clustering employant différents prototypes de clusters et différentes mesures de distance ont été proposés dans la littérature, tels que l'algorithme FCM [EMA 98], l'algorithme de Gustafson-Kessel (GK) [GUS 79] et l'algorithme de Gath-Geva (GG) [ABO 01]. A titre d'exemple, l'algorithme FCM utilise la norme euclidienne pour la mesure de distance entre les données et les centres des clusters (prototypes). Cela conduit à rechercher des clusters de formes sphériques. Gustafson et Kessel ont, par ailleurs, développé une variante relativement différente du FCM qui permet de détecter des clusters hyper-ellipsoïdaux. Les prototypes sont entièrement définis par les centres des clusters et les matrices de covariance associées. L'algorithme GK, qui fera l'objet de la section suivante, est reconnu d'être le plus adéquat pour l'identification des modèles flous.

4.2. Algorithme de clustering de Gustafson-Kessel (GK)

Comme il vient d'être souligné, l'algorithme de clustering GK permet de rechercher des clusters de formes ellipsoïdales. La distance entre un élément $\mathbf{z}_k \in \mathbf{Z}$ et un cluster P_i est définie par :

$$d_{ik}^2(\mathbf{z}_k, \mathbf{v}_i) = \|\mathbf{z}_k - \mathbf{v}_i\|_{\mathbf{M}_i}^2 = (\mathbf{z}_k - \mathbf{v}_i)^T \mathbf{M}_i (\mathbf{z}_k - \mathbf{v}_i) \quad (3.18)$$

où $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c]$ un vecteur composé des centres $\mathbf{v}_i \in \mathfrak{R}^{n+1}$ des clusters à déterminer, et $\mathbf{M}_i = \det(\mathbf{F}_i)^{1/(n+1)} \mathbf{F}_i^{-1}$ une matrice symétrique et définie-positive qui dépend de la matrice de covariance \mathbf{F}_i du i ème prototype. La minimisation de la fonction objective (3.16) passe par la détermination de ses points stationnaires selon le formalisme de Lagrange.

- **Lemme 1 :** Si $d_{ik} > 0, \forall i, k$, et $\delta > 1$, alors la paire (\mathbf{U}, \mathbf{V}) minimiserait (3.16) sous les contraintes (3.17) seulement si

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c [d_{ik}(\mathbf{z}_k, \mathbf{v}_i) / d_{jk}(\mathbf{z}_k, \mathbf{v}_j)]^{\frac{2}{\delta-1}}}, \quad (1 \leq i \leq c, 1 \leq k \leq N) \quad (3.19)$$

et

$$\mathbf{v}_i = \frac{\sum_{k=1}^N (\mu_{ik})^\delta \mathbf{z}_k}{\sum_{k=1}^N (\mu_{ik})^\delta}, \quad (1 \leq i \leq c) \quad (3.20)$$

- **Preuve :** Considérons la fonction objective (3.16) avec la mesure de distance $d^2(\mathbf{z}_k, P_i)$ telle que définie dans (3.18). Le Lagrangien associé au problème en question s'écrit :

$$L(\mathbf{Z}; \mathbf{U}, \mathbf{V}, \boldsymbol{\lambda}) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^\delta (\mathbf{z}_k - \mathbf{v}_i)^T \mathbf{M}_i (\mathbf{z}_k - \mathbf{v}_i) + \sum_{k=1}^N \lambda_k \left[\sum_{i=1}^c \mu_{ik} - 1 \right] \quad (3.21)$$

Le calcul des gradients de L par rapport à \mathbf{U} , \mathbf{V} et $\boldsymbol{\lambda}$ conduit aux équations suivantes :

$$\frac{\partial L}{\partial \mu_{ik}} = 0 \Rightarrow \delta (\mu_{ik})^{\delta-1} (\mathbf{z}_k - \mathbf{v}_i)^T \mathbf{M}_i (\mathbf{z}_k - \mathbf{v}_i) + \lambda_k = 0 \quad (3.22)$$

$$\frac{\partial L}{\partial \mathbf{v}_i} = 0 \Rightarrow -\sum_{k=1}^N (\mu_{ik})^\delta \mathbf{z}_k + \mathbf{v}_i \sum_{k=1}^N (\mu_{ik})^\delta = 0 \quad (3.23)$$

$$\frac{\partial L}{\partial \lambda_k} = 0 \Rightarrow \sum_{i=1}^c \mu_{ik} - 1 = 0 \quad (3.24)$$

À partir de l'équation (3.22) et dans le cas où $d_{ik} > 0, \forall i, k$ et $\delta > 1$, on obtient :

$$\mu_{ik} = \frac{(\lambda_k)^{\frac{1}{\delta-1}}}{[-\delta d_{ik}^2(\mathbf{z}_k, \mathbf{v}_i)]^{\frac{1}{\delta-1}}} \quad (3.25)$$

En reportant ce résultat dans l'équation (3.24), on aura :

$$\sum_{l=1}^c \frac{(\lambda_k)^{\frac{1}{\delta-1}}}{[-\delta d_{ik}^2(\mathbf{z}_k, \mathbf{v}_l)]^{\frac{1}{\delta-1}}} = 1 \quad (3.26)$$

L'équation (3.25) permet d'établir l'expression de λ_k qui, après être remplacée dans l'équation (3.26), conduit à la relation suivante :

$$\mu_{ik} = \frac{[d_{ik}^2(\mathbf{z}_k, \mathbf{v}_i)]^{\frac{1}{\delta-1}}}{\sum_{j=1}^c [d_{jk}^2(\mathbf{z}_k, \mathbf{v}_j)]^{\frac{1}{\delta-1}}} = \frac{1}{\sum_{j=1}^c [d_{ik}(\mathbf{z}_k, \mathbf{v}_i)/d_{jk}(\mathbf{z}_k, \mathbf{v}_j)]^{\frac{2}{\delta-1}}} \quad (3.27)$$

d'où la première condition nécessaire (3.19).

De façon équivalente, les centres des clusters s'obtiennent à partir de l'équation (3.23). En effet, puisque $\sum_{k=1}^N \mu_{ik} > 0$ selon (3.17), on déduit :

$$\mathbf{v}_i = \frac{\sum_{k=1}^N (\mu_{ik})^\delta \mathbf{z}_k}{\sum_{k=1}^N (\mu_{ik})^\delta} \quad (3.28)$$

d'où la deuxième condition nécessaire (3.20). ■

En se basant sur ce qui précède, la minimisation du critère (3.16) s'effectue de manière itérative sur les équations (3.19) et (3.20) jusqu'à satisfaire la condition $\|\mathbf{U}^{(l)} - \mathbf{U}^{(l-1)}\| < \varepsilon$, où l désigne l'itération en cours et ε la précision souhaitée.




Figure 3.2 : Hyper-ellipsoïde d'équation $(\mathbf{z} - \mathbf{v})^T \mathbf{F}^{-1} (\mathbf{z} - \mathbf{v}) = cste$

L'algorithme GK a l'avantage de caractériser au mieux la structure géométrique des clusters par rapport à d'autres algorithmes d'identification de modèles flous. En effet, il permet de détecter des clusters de formes et d'orientations différentes dans le même ensemble de données [BRU 96]. Pour décrire la forme et l'orientation d'un cluster, on utilise sa matrice de covariance \mathbf{F}_i qui est donnée par [GUS 79; ZHA 94] :

$$\mathbf{F}_i = \frac{\sum_{k=1}^N (\mu_{ik})^\delta (\mathbf{z}_k - \mathbf{v}_i)(\mathbf{z}_k - \mathbf{v}_i)^T}{\sum_{k=1}^N (\mu_{ik})^\delta} \quad (3.29)$$

Dans le cas où les données situées autour du centre \mathbf{v}_i forment un cluster ellipsoïdal, les directions des principaux axes de l'ellipsoïde seront données approximativement par les vecteurs propres de la matrice \mathbf{F}_i , et leurs longueurs relatives par les valeurs propres correspondantes, comme illustré à la figure 3.2. Des sous-espaces linéaires de l'espace de données \mathbf{Z} sont alors représentés par des hyper-ellipsoïdes "plats" que l'on peut assimiler, à un certain degré, à des hyperplans. Le vecteur propre correspondant à la petite valeur propre de \mathbf{F}_i détermine la normale à l'hyperplan, et peut être utilisé pour le calcul direct des paramètres des modèles locaux linéaires figurant dans les conclusions des règles floues [BRU 96; ZHA 94; LV 04].

✧ Formulation de l'algorithme GK

Etant donné un ensemble d'observations entrées-sorties \mathbf{Z} , un nombre de clusters c ($1 < c < N$). Choisir $\delta > 1$ et un seuil d'arrêt $\varepsilon > 0$. Initialiser aléatoirement la matrice de partition floue \mathbf{U} de telle sorte que les conditions (3.17) soient remplies.

Répéter pour $l = 1, 2, \dots$

- **Étape 1** : Calculer les centres des clusters :

$$\mathbf{v}_i^{(l)} = \frac{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^\delta \mathbf{z}_k}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^\delta}, \quad (1 \leq i \leq c)$$

- **Étape 2** : Calculer les matrices de covariance :

$$\mathbf{F}_i = \frac{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^\delta (\mathbf{z}_k - \mathbf{v}_i^{(l)})(\mathbf{z}_k - \mathbf{v}_i^{(l)})^T}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^\delta}, \quad (1 \leq i \leq c)$$

- **Étape 3** : Evaluer les distances :

$$\mathbf{M}_i = \det(\mathbf{F}_i)^{1/(n+1)} \mathbf{F}_i^{-1},$$

$$d_{ik}^2 = (\mathbf{z}_k - \mathbf{v}_i^{(l)})^T \mathbf{M}_i (\mathbf{z}_k - \mathbf{v}_i^{(l)}), \quad (1 \leq i \leq c, 1 \leq k \leq N)$$

- **Étape 4** : Actualiser la matrice de partition floue :

pour $1 \leq i \leq c, 1 \leq k \leq N$

si $d_{ik} > 0$

$$\mu_{ik}^{(l)} = \frac{1}{\sum_{j=1}^c [d_{ik}/d_{jk}]^{\frac{2}{\delta-1}}}$$

sinon si $d_{ik} = 0$

$$\mu_{ik}^{(l)} = 1$$

Jusqu'à satisfaire $\|\mathbf{U}^{(l)} - \mathbf{U}^{(l-1)}\| < \varepsilon$.

4.3. Génération des fonctions d'appartenance

Une première constatation que l'on puisse faire est que l'algorithme GK tel qu'il est décrit dans la section précédente ne fournit pas, de façon directe, les paramètres des prémisses des règles du modèle flou TS identifié. En effet, ces paramètres seront plutôt extraits de la matrice de partition floue \mathbf{U} générée à la fin du clustering. Les zones de

validité des clusters identifiés, qui coïncident exactement avec les zones de fonctionnement du processus dynamique en question, sont totalement représentées dans la matrice \mathbf{U} . Pour compléter l'analyse, réécrivons le modèle flou TS (3.9) sous la forme compacte suivante :

$$\begin{aligned} R^i : & \text{ If } \mathbf{x} \text{ is } \mathbf{A}^i \\ & \text{ Then } y^i = \boldsymbol{\theta}_i^T \mathbf{x} \quad (1 \leq i \leq c) \end{aligned} \quad (3.30)$$

où \mathbf{A}^i un ensemble flou multidimensionnel caractérisé par une fonction d'appartenance à plusieurs variables $\mu_{\mathbf{A}^i}(\mathbf{x}) : \mathfrak{R}^n \rightarrow [0, 1]$, et $\boldsymbol{\theta}_i = [a_1^i, \dots, a_n^i, b^i]^T$ le vecteur des paramètres du i ème modèle local.

Comme nous l'avons déjà souligné, un élément μ_{ik} de la matrice de partition floue \mathbf{U} représente le degré d'appartenance de \mathbf{z}_k au cluster P_i . Ainsi, la i ème ligne de \mathbf{U} correspond bien aux valeurs de la i ème fonction d'appartenance dans la partition floue. De ce fait, les degrés d'activation normalisés des règles floues R^i coïncident exactement avec les éléments de la matrice \mathbf{U} , ce qui permet d'écrire :

$$\mu_{ik} = \mu_{\mathbf{A}^i}(\mathbf{z}_k) = \frac{[d_{ik}^2]^{-\frac{1}{\delta-1}}}{\sum_{j=1}^c [d_{jk}^2]^{-\frac{1}{\delta-1}}} \quad (3.31)$$

où d_{ik}^2 est la distance entre \mathbf{z}_k et le centre du cluster P_i dans l'algorithme GK.

Pour le besoin d'interprétation des modèles flous TS, nous sommes souvent amenés à manipuler des fonctions d'appartenance unidimensionnelles. Pour ce faire, il est nécessaire de décomposer l'ensemble \mathbf{A}^i en n ensembles flous unidimensionnels A_j^i en tenant compte du mécanisme d'inférence considéré dans la section 3.2, *i.e.*

$$\mu_{\mathbf{A}^i}(\mathbf{x}) = \prod_{j=1}^n \mu_{A_j^i}(x_j) \quad (3.32)$$

Dans ce sens, deux approches distinctes peuvent être employées. La première est une approximation basée sur la projection orthogonale de $\mu_{\mathbf{A}^i}(\mathbf{x})$ sur chacun des axes. Cette approximation pourrait induire des erreurs de décomposition qui peuvent être compensées, à un certain degré, par la ré-estimation des paramètres $\boldsymbol{\theta}_i$ [ABO 01]. Néanmoins, la ré-estimation des paramètres influe considérablement sur l'interprétabilité du modèle flou TS car les modèles locaux qui en découlent ne seront plus liés à la linéarisation dynamique du modèle non linéaire (3.1).

La deuxième approche, dite approche du domaine d'entrée transformé, s'avère plus tolérante aux erreurs de décomposition. Elle est essentiellement basée sur la projection des vecteurs propres des matrices de covariances définies par (3.29). Le principe de la méthode est brièvement exposé dans ce qui suit.

Désignons par η_j^i et \mathfrak{S}_j^i , $j = 1, \dots, n$, les valeurs propres et les vecteurs propres des matrices de covariance \mathbf{F}_i , ($i = 1, \dots, c$), respectivement. Par projection des vecteurs propres dans l'espace de décision transformé, il en résulte le modèle flou suivant :

$$\begin{aligned} R^i : & \text{ If } \tilde{x}_1 \text{ is } A_1^i \text{ and } \tilde{x}_2 \text{ is } A_2^i \text{ and } \dots \text{ and } \tilde{x}_n \text{ is } A_n^i \\ & \text{ Then } y^i = \boldsymbol{\theta}_i^T \mathbf{x}, \quad (1 \leq i \leq c) \end{aligned} \quad (3.33)$$

où $\tilde{x}_j = \mathfrak{S}_j^{iT} \mathbf{x}$, $j = 1, \dots, n$, sont les variables de décision transformées. Dans le cas où l'on utilise des fonctions d'appartenance gaussiennes dans les prémisses des règles *i.e.*

$$\mu_{A_j^i}(\tilde{x}_{kj}) = \exp\left(-\frac{1}{2} \frac{(\tilde{x}_{kj} - v_j^i)^2}{\sigma_j^{i2}}\right) \quad (3.34)$$

leurs centres seront donnés par $v_j^i = \mathfrak{S}_j^{iT} \mathbf{v}_i$ et leurs variances par $\sigma_j^{i2} = \eta_j^{i2}$.

4.4. Estimation des paramètres

Les paramètres des modèles locaux dans la conclusion de chaque règle floue peuvent être estimés à l'aide de méthodes appropriées d'estimation paramétrique, telles que la méthode des moindres carrés ordinaires (OLS) ou la méthode du filtre de Kalman (RLS) [YAG 94], ou encore par l'utilisation de la matrice de covariance des clusters identifiés. Dans la méthode OLS, on distingue deux principales approches : la première, dite locale, requiert la résolution de c problèmes d'optimisation (un problème pour chaque règle). La deuxième envisage la résolution d'un problème OLS global défini sur le modèle flou résultant de l'agrégation de l'ensemble des règles. L'approche OLS locale s'avère plus intéressante car elle permet de surmonter le problème de compensation des paramètres, préservant ainsi la validité du modèle flou identifié [SET 00]. Dans la suite, l'approche OLS locale est considérée.

Considérons la matrice de régression étendue $\mathbf{X}_e = [\mathbf{X} \mathbf{1}]$, et le vecteur des paramètres $\boldsymbol{\theta}_i = [a_1^i \dots a_n^i, b^i]^T$. Dans l'approche OLS, l'estimation des paramètres $\boldsymbol{\theta}_i$ est généralement réalisée par la minimisation du critère :

$$E(\boldsymbol{\theta}_i) = \frac{1}{N} (\mathbf{y} - \mathbf{X}_e \boldsymbol{\theta}_i)^T \boldsymbol{\Psi}_i (\mathbf{y} - \mathbf{X}_e \boldsymbol{\theta}_i) \quad (3.35)$$

avec $\Psi_i \in \mathfrak{R}^{N \times N}$ une matrice diagonale ayant pour éléments les degrés d'activation normalisés μ_{ik} des règles floues R^i . La matrice Ψ_i est donnée par :

$$\Psi_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{iN} \end{bmatrix} = \begin{bmatrix} \Phi_i(\mathbf{x}_1) & 0 & \dots & 0 \\ 0 & \Phi_i(\mathbf{x}_2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \Phi_i(\mathbf{x}_N) \end{bmatrix} \quad (3.36)$$

Les paramètres locaux θ_i seront alors évalués par la formule suivante :

$$\theta_i = [\mathbf{X}_e^T \Psi_i \mathbf{X}_e]^{-1} \mathbf{X}_e^T \Psi_i \mathbf{y} \quad (3.37)$$

5. Utilisation des modèles flous TS pour la surveillance

Les méthodes de détection et de diagnostic des défauts présentées dans le chapitre 2 reposent toutes sur un modèle mathématique du processus à surveiller. Le recours à l'une ou l'autre méthode est non seulement guidé par l'application appréhendée mais aussi par le type du modèle que nous disposons et le contexte dans lequel il sera utilisé. Comme il vient d'être souligné, leur applicabilité est principalement subordonnée par la qualité du modèle employé. En effet, devant l'exigence croissante de robustesse imposée sur les systèmes de surveillance et de supervision, un modèle décrivant des excursions limitées des variables du processus surveillé a moins de chance d'être satisfaisant. Nous sommes donc amenés à manipuler des modèles plus ou moins complexes dans la conception des algorithmes de surveillance.

A première vue, il n'est sans doute pas difficile de remarquer que les modèles flous TS offrent une structure intéressante pour la conception d'algorithmes de surveillance. Plusieurs méthodes de surveillance se basant sur les modèles flous ont été développées ces dernières années. Parmi ces approches, citons la méthode de détection et d'isolation de défauts basée sur l'utilisation d'observateurs flous [ALC 03]. Le principe de cette approche consiste à identifier un modèle flou pour le système surveillé en mode sain et à chaque mode de défaut. Lors de la surveillance, l'ensemble de ces modèles génère en parallèle des erreurs de prédiction qui sont évaluées pour décider du modèle le plus adéquat. Chaque modèle étant associé à un mode de défaillance ou au mode nominal, la détection et le diagnostic sont ainsi simultanément réalisés. L'inconvénient principal de cette méthode réside dans le fait que, pour les procédés industriels réels, les signaux mesurés avec des défauts sont rarement disponibles. De plus, il faut collecter une grande quantité de signaux à chaque mode et pour différentes amplitudes de défauts, ce qui est difficile à envisager en pratique.

Dans d'autres approches, le vecteur de paramètres θ est utilisé pour la détection des défauts. Ainsi on peut déceler des anomalies correspondant à des changements dans les




Figure 3.3 : Génération des résidus de détection.

constantes de temps, les gains statiques, les zéros des fonctions de transfert ou encore les offsets [BAL 97; BAL 00]. Toutefois, lorsque les paramètres θ ne possèdent pas d'interprétation physique ou ne sont pas liés à la linéarisation dynamique du processus surveillé, il serait impossible d'effectuer le diagnostic de ces défauts. Même pour la détection seule, cette méthode peut entraîner des fausses alarmes lorsque le modèle flou utilisé est surparamétré.

Nous introduisons dans la suite une technique de génération des résidus de détection se basant sur l'erreur de sortie (section 2.1.1), avant de présenter une méthode qui permet d'évaluer ces résidus en vue d'isoler les défauts survenus.

5.1. Génération de résidus

Considérons le cas général d'un processus dynamique non linéaire pouvant être représenté par un modèle non linéaire auto-régressif avec entrée exogène (NARX) de type MIMO. Ce processus peut être décomposé en un ensemble de sous-systèmes MISO décrit chacun par un modèle du type (3.1). Le modèle flou du processus MIMO résulte ainsi de la composition de l'ensemble des modèles flous TS identifiés pour chaque sous-système MISO à partir des signaux entrées-sorties mesurés. Chaque modèle flou TS est de la forme (3.9).

Les résidus de détection sont obtenus en comparant les sorties mesurées $y(k)$ et les sorties estimées $\hat{y}(k)$, comme le montre bien la figure 3.3, *i.e.*

$$\mathbf{r}(k) = \mathbf{y}(k) - \hat{\mathbf{y}}(k) \quad (3.38)$$

Pour le besoin d'isolation de défauts, la seule information issue du modèle flou identifié en régime sain est loin d'être suffisante. Il est nécessaire d'employer des

signaux redondants générés de manière à permettre la localisation et l'identification du défaut survenu. Ces signaux sont, dans notre cas, issus de prédicteurs flous représentés par des modèles flous TS. Ces prédicteurs sont identifiés en mode sain à partir des mesures entrées-sorties. En employant des variables de décision différentes pour chaque prédicteur, nous pourrions générer une séquence de résidus indicateurs d'anomalies permettant dans l'ensemble d'isoler ces défauts. Après évaluation des résidus, une logique de décision est par la suite employée pour décider de l'occurrence ou non du défaut.

5.2. Evaluation des résidus

Pour certains résidus et dans le cas où l'amplitude du défaut est faible, le rapport signal-bruit est trop petit, chose qui rend difficile l'utilisation d'un simple seuillage pour décider de l'occurrence ou non du défaut. Aussi, les processus industriels opèrent en général dans un environnement purement stochastique, ce qui impose l'adoption d'une procédure de décision qui fait plutôt appel à des approches probabilistes pour une évaluation optimale de ces résidus de détection. L'algorithme de somme cumulée (CUSUM), basé sur le test du rapport de vraisemblance [BAS 93], est l'un des algorithmes d'évaluation établis dans ce sens. Formulée dans un cadre statistique, la méthode CUSUM propose d'exploiter les propriétés statistiques des signaux pour la détection de changements. En effet, les résidus possèdent des propriétés asymptotiques très intéressantes qui permettent de transformer la détection et le diagnostic des défauts en un problème asymptotiquement équivalent qui est la détection et le diagnostic de changements dans la moyenne d'un vecteur gaussien.

5.2.1. Méthode de somme cumulée (CUSUM)

Considérons le vecteur résiduel $\mathbf{r}(k) \in \mathfrak{R}^q$ de moyenne $\mathbf{v} = \mathbf{v}_0$ et de variance Σ (une matrice définie positive). L'objectif est de choisir entre l'hypothèse sans défauts \mathcal{H}_0 et l'hypothèse des défauts \mathcal{H}_1 :

$$\mathcal{H}_0: \mathcal{L}(\mathbf{r}(i)) = \mathcal{N}(\mathbf{v}_0, \Sigma), \quad 1 \leq i \leq k \quad (3.39)$$

$$\mathcal{H}_1: \mathcal{L}(\mathbf{r}(i)) = \mathcal{N}(\mathbf{v}_0, \Sigma), \quad 1 \leq i \leq k_0 - 1 \text{ et } \mathcal{L}(\mathbf{r}(i)) = \mathcal{N}(\mathbf{v}_1, \Sigma), \quad k_0 \leq i \leq k \quad (3.40)$$

avec $\mathbf{v}_1 \neq \mathbf{v}_0$

où \mathbf{v}_1 un vecteur, supposé connu, caractérisant l'amplitude des défauts, et k_0 est l'instant d'occurrence du défaut (paramètre inconnu).

Avec ces notations, et en utilisant la forme vectorielle de la densité de probabilité d'une séquence gaussienne de moyenne \mathbf{v} et de variance Σ :

$$p_{\mathbf{v}}(\mathbf{r}(k)) = \frac{1}{\sqrt{(2\pi)^q \det \Sigma}} \exp\left(-\frac{1}{2}(\mathbf{r}(k) - \mathbf{v})^T \Sigma^{-1}(\mathbf{r}(k) - \mathbf{v})\right) \quad (3.41)$$

le rapport de vraisemblance entre \mathcal{H}_0 et \mathcal{H}_1 s'écrit :

$$s(\mathbf{r}(k)) = \ln \frac{p_{\mathbf{v}_1}(\mathbf{r}(k))}{p_{\mathbf{v}_0}(\mathbf{r}(k))} = (\mathbf{v}_1 - \mathbf{v}_0)^T \Sigma^{-1} \left(\mathbf{r}(k) - \frac{1}{2}(\mathbf{v}_0 + \mathbf{v}_1) \right) \quad (3.42)$$

Ce rapport possède les propriétés statistiques fondamentales suivantes [BAS 93] :

$$E_{\mathbf{v}_0}(s) < 0 \text{ et } E_{\mathbf{v}_1}(s) > 0 \quad (3.43)$$

où $E_{\mathbf{v}_0}(s)$ et $E_{\mathbf{v}_1}(s)$ désignent respectivement les espérances mathématiques de $s(\mathbf{r})$ associées aux distributions gaussiennes $p_{\mathbf{v}_0}(\mathbf{r})$ et $p_{\mathbf{v}_1}(\mathbf{r})$.

Ainsi, et à partir des propriétés (3.43), il a été montré dans [BAS 93] que la somme cumulée

$$S(k) = \sum_{i=1}^k s(\mathbf{r}(i)) = \sum_{i=1}^k \ln \frac{p_{\mathbf{v}_1}(\mathbf{r}(i))}{p_{\mathbf{v}_0}(\mathbf{r}(i))} \quad (3.44)$$

manifeste une pente négative en absence de défauts et une pente positive en présence de défauts. Les résultats publiés par Neyman et Pearson [BLA 03] montrent que la fonction de décision optimale associée au problème (3.39)-(3.40) est donnée par :

$$g(k) = \max_{1 \leq j \leq k} \sum_{i=j}^k s(\mathbf{r}(i)) \quad (3.45)$$

et la détection est effectuée par les règles :

$$\text{si } g(k) \leq h \quad \text{admettre } \mathcal{H}_0 \quad (3.46)$$

$$\text{si } g(k) > h \quad \text{admettre } \mathcal{H}_1 \quad (3.47)$$

où h est un seuil à choisir selon la probabilité des fausses alarmes souhaitée. Le choix de h est discuté plus loin dans la section 5.2.2.

Une manière efficace d'implémenter l'algorithme CUSUM consiste à utiliser la forme récursive de la fonction de décision $g(k)$ déduite de (3.45). Celle-ci est donnée par :

$$g(k) = \max(0, g(k-1) + s(\mathbf{r}(k))) \quad (3.48)$$

Dans le cas où l'hypothèse \mathcal{H}_1 est retenue, l'instant d'occurrence du défaut \hat{k}_0 est estimé par :

$$\hat{k}_0 = k_a - N_g(k_a) \quad (3.49)$$

où k_a est l'instant d'alarme, et $N_g(k)$ désigne le nombre d'observations successives pour lesquelles la fonction de décision $g(k)$ est strictement positive. $N_g(k)$ est calculé à l'aide de l'expression suivante :

$$N_g(k) = N_g(k-1) \cdot \mathbf{1}_{\{g(k-1)>0\}} + 1 \quad (3.50)$$

où $\mathbf{1}_{\{g(k-1)>0\}}$ indique la réalisation ou non de la condition $g(k-1) > 0$.

Notons que la formulation vectorielle du CUSUM, telle que décrite dans ce qui précède, peut s'avérer plus adéquate en pratique pour la simple raison est qu'elle permet de traiter de façon globale l'ensemble des signaux de détection et fournit, par conséquent, une décision qui dépend de l'évolution de l'ensemble de ces signaux.

5.2.2. Paramètres de conception dans l'algorithme CUSUM

La moyenne et la variance du vecteur résiduel $\mathbf{r}(k)$ sont estimées à partir des mesures entrées-sorties obtenues en régime de fonctionnement sain. Désignons ces valeurs estimées par $\hat{\mathbf{v}}_0$ et $\hat{\Sigma}$, respectivement. Les autres paramètres de conception à choisir sont le seuil de décision h et l'amplitude du changement \mathbf{v}_1 . Bien que \mathbf{v}_1 étant supposé connu (c'est justement le cas en pratique), le fait de le remplacer par une valeur approchée n'affecte en rien l'efficacité de l'algorithme [BLA 03].

Le choix de h résulte généralement d'un compromis entre la probabilité des fausses alarmes et le délai moyen de détection souhaités. Ces deux quantités peuvent être évaluées à l'aide d'une fonction dite ARL (*Average run length*) [BLA 03], qui fournit une estimation du délai de détection lorsque les données sont distribuées suivant la loi normale $\mathcal{N}(\mathbf{v}, \Sigma)$. Une approximation de la fonction ARL dans le cas où l'on envisage la détection de changements dans la moyenne d'une séquence gaussienne est donnée par l'expression suivante :

$$\Xi(\mathbf{v}_s) = \left(\exp \left[-2 \left(\frac{\mathbf{v}_s h}{\sigma_s^2} + 1.166 \frac{\mathbf{v}_s}{\sigma_s} \right) \right] - 1 + 2 \left(\frac{\mathbf{v}_s h}{\sigma_s^2} + 1.166 \frac{\mathbf{v}_s}{\sigma_s} \right) \right) \left(\frac{\sigma_s^2}{2\mathbf{v}_s^2} \right) \quad (3.52)$$

avec $v_s \neq 0$. Les paramètres v_s et σ_s désignent respectivement la moyenne et l'écart type de la somme cumulée (3.44). Le temps de retard moyen à la détection $\hat{\tau}$ et le temps moyen entre les fausses alarmes $\hat{\kappa}$ peuvent être alors estimés par :

$$\hat{\tau} = \Xi \left(\frac{(\mathbf{v}_1 - \hat{\mathbf{v}}_0)^T \boldsymbol{\Sigma}^{-1} (\mathbf{v}_1 - \hat{\mathbf{v}}_0)}{2} \right) \quad (3.53)$$

$$\hat{\kappa} = \Xi \left(- \frac{(\mathbf{v}_1 - \hat{\mathbf{v}}_0)^T \boldsymbol{\Sigma}^{-1} (\mathbf{v}_1 - \hat{\mathbf{v}}_0)}{2} \right) \quad (3.54)$$

6. Conclusions

Ce chapitre est consacré au problème d'identification des modèles flous et leur utilisation pour la surveillance. La méthode d'identification étudiée est de type boîte-noire non linéaire. Plus précisément, c'est l'algorithme de clustering de Gustafson-Kessel (GK) qui est considéré. La dérivation de l'algorithme GK repose sur la résolution d'un problème d'optimisation non linéaire appliqué à une base de données entrées-sorties. Le problème de mise œuvre de cet algorithme se situe essentiellement au niveau des paramètres initiaux à choisir, notamment le nombre optimal de clusters. Dans ce sens, deux approches peuvent être envisagées : la première est de poser un nombre surestimé de clusters pour procéder à la fin du clustering à la réduction de la structure du modèle obtenu à l'aide de mécanismes appropriés, la deuxième approche exploite les connaissances disponibles a priori sur le processus à identifier. Le modèle flou résultant est assimilable à un multimodèle. Son utilisation pour la surveillance est intéressante car, d'une part, il s'agit d'un modèle non linéaire à structure flexible pouvant couvrir la totalité du domaine opératoire selon les observations entrées-sorties réalisées, d'autre part, les schémas de génération de résidus se basant sur ce modèle peuvent servir à la détection et l'isolation simultanées des défauts. L'application de l'approche floue à l'identification et la surveillance d'un échangeur de chaleur est intégralement exposée dans le chapitre 4.

Chapitre 4

Application de l'approche floue à la surveillance d'un échangeur de chaleur

1. Introduction

Les notions et les outils d'identification et de surveillance abordés dans les chapitres 1, 2 et 3 constituent une base commune à certaines démarches d'analyse et de conception de systèmes de diagnostic, tout au moins pour les méthodes basées sur l'utilisation de modèles. Le test et la mise en œuvre de ces techniques sont les étapes qui doivent nécessairement suivre les phases d'analyse et de synthèse car, d'un point de vue méthodologique, toutes les approches que l'on cherche à développer dans ce domaine se ramènent à terme à une application qui doit les justifier. Dans ce sens, et afin d'apporter une justification à l'applicabilité de l'approche floue développée le long de cette thèse, nous avons mené une étude expérimentale traitant le problème particulier de la détection et le diagnostic de défauts dans un échangeur de chaleur pilote.

L'étude expérimentale est réalisée à l'Université Libre de Bruxelles (ULB) et se situe, plus précisément, au niveau de l'identification de l'échangeur de chaleur avec des modèles flous, et de la détection et du diagnostic de défauts avec une approche basée sur ces modèles. L'échangeur de chaleur en question a déjà fait l'objet de plusieurs travaux dans lesquels étaient abordés certains problèmes liés à sa modélisation et sa surveillance. En effet, Peng *et al.* ont développé dans [PEN 97] une procédure complète de génération et d'évaluation de résidus qu'ils ont appliqué, ensuite, à l'échangeur de chaleur de la figure 4.1. Leur méthode est basée sur un modèle d'état linéaire du processus, identifié à partir de mesures entrées-sorties à l'aide de la méthode modale. Pour l'identification des défauts de capteurs et d'actionneurs considérés, une procédure d'évaluation utilisant le test du rapport de vraisemblance généralisé (GLR) [BAS 93] a




Figure 4.1 : Schéma synoptique de l'échangeur de chaleur pilote.

été utilisée. Leur approche utilise donc un modèle de comportement local (modèle d'état) et, par conséquent, l'algorithme de surveillance développé a moins de chance d'être robuste vis-à-vis la variation du point de fonctionnement.

Notre contribution, qui intervient justement à ce niveau, vise à mettre en œuvre un système de surveillance qui s'adapte au mieux à la variation du point de fonctionnement de l'échangeur de chaleur par la manipulation d'un modèle non linéaire couvrant la totalité de son domaine opératoire. Ce choix est motivé par le désir d'asseoir les problèmes d'identification et de surveillance des processus dynamiques complexes, tels que l'échangeur de chaleur, sur des bases méthodologiques qui permettent de les traiter suivant une approche globale conduisant à des structures de modèles et d'algorithmes assez flexibles.

Dans la suite, nous exposons l'ensemble des essais réalisés dans le cadre de cette étude expérimentale en les situant dans le contexte concerné. Les détails concernant l'installation pilote et les conditions de réalisation des expériences sont aussi présentés.



Figure 4.2 : Vue d'ensemble de l'échangeur de chaleur.

Enfin, nous faisons la synthèse des résultats d'identification obtenus et les résultats d'implémentation et de mise en œuvre de l'algorithme de surveillance développé.

2. Description de l'échangeur de chaleur

L'échangeur de chaleur est l'élément principal de l'installation pilote du laboratoire. Cette installation est schématisée dans son ensemble par la figure 4.1. Elle se ramène à trois principaux sous-systèmes : un dispositif de chauffe, un circuit d'air et un circuit d'eau. L'échangeur de chaleur en question est du type courant parallèle (co-courant), assurant le réchauffement de l'eau par de l'air. La figure 4.2 donne une vue d'ensemble du processus appréhendé.

2.1. Circuit d'air

Le circuit d'air comporte un ventilateur (V) tournant à vitesse constante et faisant circuler l'air provenant d'un caisson où se mélangent l'air aspiré à l'ambiance et celui provenant du recyclage. Cet air arrive à l'admission d'un dispositif de chauffe avec une température T_{13} . Il est ensuite chauffé dans six sections de chauffage commandées par un dispositif de commande de puissance à base de thyristors. Après avoir parcouru une




Figure 4.3 : Systèmes de câblage et de prise de mesures de l'installation pilote.

conduite assez longue, l'air, porté à une température T_{14} à la sortie du dispositif de chauffe, arrive à l'entrée de l'échangeur de chaleur, proprement dit, avec une température T_{16} . Ce dernier est enfin évacué ou recyclé en totalité ou en partie. Le débit d'air dans l'échangeur et le taux de recyclage sont conditionnés par la position de deux vannes papillons, l'une située dans la conduite d'évacuation, l'autre dans la conduite de recyclage. Les servomécanismes utilisés pour réaliser le positionnement des deux vannes sont constitués de moteurs de type série à deux inducteurs, commandant chacun un sens de rotation, d'un réducteur et d'un potentiomètre de position.

2.2. Circuit d'eau

L'alimentation en eau est assurée par un réservoir à niveau constant. Ce dernier alimente une pompe centrifuge actionnée par un moteur de type série dont la tension d'alimentation est réglée par un dispositif à semi-conducteur commandé. Arrivée à l'admission de l'échangeur avec une température T_{33} , l'eau est portée à une certaine température T_{34} avant d'être évacuée pour une éventuelle utilisation. Les conduites d'entrée et de sortie de l'eau sont connectées à deux collecteurs, pourvus de thermistances, desquels partent et arrivent cinq nappes de tubes de cuivre. Chaque nappe s'étend sur 0,33 m et est constituée de 24 tubes ayant chacun un diamètre intérieur de 3 mm et extérieur de 5 mm. La longueur totale de ces tubes est de 7,5 m. Chaque tube est disposé perpendiculairement à la direction de l'air et à cette échelle nous avons donc un échangeur à courant perpendiculaire. Toutefois, le mouvement

d'ensemble de l'eau se fait parallèlement à l'air et dans le même sens, raison pour laquelle il est considéré comme échangeur à courant parallèle.

2.3. Dispositif de chauffe

Le chauffage de l'air est assuré par 12 grilles, de 1 KW chacune, groupées deux par deux en six sections de chauffage. Le circuit de commande de la puissance de chauffe est réalisé à l'aide de deux thyristors suivant un arrangement particulier permettant d'avoir une commande quasi linéaire et continue sur toute la gamme opératoire tout en ayant une puissance installée en thyristors minimale. Le thyristor est allumé par des impulsions générées par un circuit de commande et déphasées par une tension continue de commande. Pour un angle de passage des thyristors variant entre 0 et π , la puissance P_c passe de 0 à 4 KW. D'autres sections de chauffage sont enclenchées lorsque la puissance demandée devient supérieure à 4 KW.

2.4. Grandeurs et organes de mesure

Pour le besoin de commande et/ou de surveillance, l'échangeur de chaleur est équipé de capteurs fournissant chacun un signal proportionnel à la variable mesurée. Le signal fourni par le capteur est traité le plus près possible de son origine pour être transmis en tension normalisée dans la gamme 0 – 10 volts vers le système de prise de mesures illustré à la figure 4.3. Les principales grandeurs mesurables sont :

P_c	puissance de chauffe [0 – 10 KW],
α_{21} et α_{22}	positions des électrovannes [0 – 100%],
Q_a	débit d'air [0 – 200 kg/m ²],
Q_e	débit d'eau [0 – 200 l/h],
T_{13} et T_{14}	températures d'air à l'entrée du dispositif de chauffe [0 – 100°C], et à sa sortie [0 – 200°C],
T_{15} et T_{16}	températures d'air à la sortie et à l'admission de l'échangeur de chaleur [0 – 100°C],
T_{33} et T_{34}	températures d'eau à l'entrée et à la sortie de l'échangeur [0 – 100°C],
T_{35} et T_{36}	températures d'eau prises à deux différents niveaux de l'échangeur de chaleur [0 – 100°C].

Le débit d'air Q_a traversant l'échangeur est mesuré à la sortie du ventilateur à l'aide d'un diaphragme à prise de pression différentielle constitué d'un transformateur alimenté par un oscillateur à 2 KHz. Ce transformateur est suivi d'un amplificateur démodulateur fournissant une tension continue proportionnelle à la chute de pression

dans le diaphragme. Le débit d'eau Q_e , quant à lui, est mesuré par une turbine dont la vitesse de rotation est proportionnelle au débit dans la gamme de 20 à 250 l/h. Un convertisseur fréquence-tension permet d'obtenir une tension continue proportionnelle au débit. Enfin, les capteurs de température sont constitués de fils de platine parcourus par un courant continu. La chute de potentiel aux bornes du capteur est une mesure de température.

3. Modèle mathématique de l'échangeur de chaleur

Dans cette section nous allons procéder à l'étude du modèle mathématique de l'échangeur de chaleur. L'établissement de ce modèle passe par la considération des différents phénomènes dynamiques dus aux échanges thermiques dans l'échangeur proprement dit, dans la conduite d'air et dans le dispositif de chauffe. Pour ce faire, il a été nécessaire d'admettre au préalable un certain nombre d'hypothèses simplificatrices dont les principales sont :

- les écoulements étant turbulents, les fluides sont bien mélangés et les températures sont uniformes dans une section normale à l'écoulement,
- la conductibilité du métal est nulle dans le sens axial et infinie dans le sens radial, et la résistance thermique eau-métal est nulle,
- la conductibilité de l'eau est nulle dans le sens axial,
- le nombre de tubes constituant une nappe est important. A cette échelle, nous avons donc un échangeur de chaleur à courant parallèle,
- les pertes de charges sont négligées et l'échangeur est supposé bien calorifugé.

Dans la suite, nous utiliserons les notations suivantes avec m, a, e des indices qui correspondent respectivement au métal, à l'air et à l'eau.

T_m, T_a, T_e	températures ($^{\circ}\text{C}$),
c_m, c_a, c_e	chaleurs spécifiques par unité de volume ($\text{Kcal}/\text{m}^3\text{C}$),
v_a, v_e	vitesse (m/s),
S_m, S_a, S_e	sections d'échange (m^2),
D_a, D_e	périmètres d'échange (m),
α_a, α_e	coefficients d'échange métal-air et métal-eau exprimés par unité de surface ($\text{Kcal}/\text{m}^2\text{s}^{\circ}\text{C}$).




Figure 4.4 : Représentation schématique de l'échange thermique.

3.1. Echange thermique air-métal-eau

Le modèle d'échange thermique s'obtient à partir du bilan énergétique des échanges thermiques métal-air et métal-eau. Le bilan énergétique par unité de longueur ($Kcal/m$) en suivant l'eau dans son mouvement s'écrit :

$$S_a c_a dT_a = \alpha_a D_a (T_m - T_a) dt \quad (4.1)$$

$$S_e c_e dT_e = \alpha_e D_e (T_m - T_e) dt \quad (4.2)$$

$$S_m c_m dT_m = \alpha_e D_e (T_e - T_m) dt + \alpha_a D_a (T_a - T_m) dt \quad (4.3)$$

Ces trois équations représentent les bilans d'énergie dans l'air, dans l'eau et dans le métal, respectivement. En faisant intervenir les vitesses d'écoulement de l'air et de l'eau, on obtient les équations suivantes :

$$S_a c_a \frac{\partial T_a(\xi, t)}{\partial \xi} v_a + l_a S_a c_a \frac{\partial T_a(\xi, t)}{\partial t} = \alpha_a D_a (T_m(t) - T_a(\xi, t)) \quad (4.4)$$

$$S_e c_e \frac{\partial T_e(\xi, t)}{\partial \xi} v_e + S_e c_e \frac{\partial T_e(\xi, t)}{\partial t} = \alpha_e D_e (T_m(t) - T_e(\xi, t)) \quad (4.5)$$

$$S_m c_m \frac{\partial T_m(t)}{\partial t} = \alpha_e D_e (T_e(\xi, t) - T_m(t)) + \alpha_a D_a (T_a(\xi, t) - T_m(t)) \quad (4.6)$$

où l_a est un facteur d'échelle (voir annexe A).

3.2. Echange thermique dans le circuit d'air

Des considérations en tous points semblables à celles qui nous ont conduit au modèle (4.4)-(4.6) décrivant les échanges métal-air et métal-eau, nous conduiront à la relation liant la température de l'air en un point en aval de la tuyauterie à celle régnant en un

point amont. Les bilans énergétiques par unité de longueur en suivant l'air dans son mouvement s'écrivent :

$$S_a c_a \frac{\partial T_a(\xi, t)}{\partial \xi} v_a + S_a c_a \frac{\partial T_a(\xi, t)}{\partial t} = \alpha_a D_a (T_m(t) - T_a(\xi, t)) \quad (4.7)$$

$$S_m c_m \frac{\partial T_m(t)}{\partial t} = \alpha_a D_a (T_a(\xi, t) - T_m(t)) \quad (4.8)$$

En introduisant les constantes d'échange thermique τ_a et τ_m , le système d'équations (4.7)-(4.8) devient :

$$\tau_a v_a \frac{\partial T_a(\xi, t)}{\partial \xi} + \tau_a \frac{\partial T_a(\xi, t)}{\partial t} = T_m(t) - T_a(\xi, t) \quad (4.9)$$

$$\tau_m \frac{\partial T_m(t)}{\partial t} = T_a(\xi, t) - T_m(t) \quad (4.10)$$

avec $\tau_a = \frac{c_a S_a}{\alpha_a D_a}$ et $\tau_m = \frac{c_m S_m}{\alpha_a D_a}$.

De même, si l'on admet que le débit d'air est constant et que la température du filament, supposé ponctuel, est proportionnelle à la puissance de chauffe P_c , l'équation du bilan thermique appliqué au dispositif de chauffe s'écrit :

$$\tau_c \frac{\partial T_a(t)}{\partial t} = k_c P_c(t) - T_a(t) \quad (4.11)$$

où k_c et τ_c sont respectivement le gain statique et la constante de temps du dispositif de chauffe.

3.3. Remarques sur le modèle mathématique établi

Bien que des hypothèses simplificatrices aient été formulées au préalable, il n'est sans doute pas difficile de constater que les modèles des échanges thermiques que l'on vient d'établir à partir des lois de la physique sont extrêmement lourds à manipuler. Les températures d'air et d'eau étant des fonctions du temps et de l'espace, les coefficients d'échange thermique sont généralement mal connus et les vitesses d'écoulement de l'air et de l'eau varient en fonction des conditions d'exploitation. Aussi, il est facile de constater que les échanges thermiques dans l'échangeur de chaleur proprement dit et dans le circuit d'air constituent tous des phénomènes à paramètres répartis obéissant à des équations aux dérivées partielles. Ces constats traduisent clairement la complexité du comportement dynamique de l'échangeur de chaleur et laissent affirmer que l'obtention d'un modèle de connaissance suffisamment représentatif du processus n'est

pas une tâche triviale. Quoiqu'il en soit, il est toujours possible d'envisager dans certains contextes d'autres hypothèses simplificatrices pour établir des modèles simplifiés régis par des équations différentielles ordinaires à paramètres constants destinés, par exemple, à la synthèse de lois de commande.

Aussi, notons que le modèle mathématique décrit dans ce qui précède ou toute autre représentation simplifiée de celui-ci ont moins de chance d'être satisfaisants pour la conception d'algorithmes de surveillance. Vu la particularité du processus appréhendé, le recours à une méthode d'identification boîte-noire non linéaire nous est avéré fort utile pour la réalisation de l'étude expérimentale. Le développement et la validation de cette approche sont exposés dans la section suivante.

4. Identification du modèle flou de l'échangeur de chaleur

Pour le besoin d'identification du comportement dynamique de l'échangeur de chaleur, nous avons fait appel à différentes sources de connaissances. Tout d'abord, la description qualitative du processus d'échange thermique fournie par l'ingénieur système et puis l'expérience du personnel technique du laboratoire avec ce type de procédé. En se basant sur ces connaissances, et compte tenu des objectifs attendus, nous avons pu situer les différentes orientations nécessaires au déroulement de l'expérimentation. Il s'agit en particulier :

- des conditions d'essais et d'exploitation de l'installation,
- du choix des variables d'entrée et de sortie du modèle flou à identifier,
- de la détermination de la structure initiale des relations floues à générer.

Le premier objectif que nous nous sommes fixés consiste à établir un modèle dynamique non linéaire à structure flexible capable de reproduire les principales caractéristiques physiques de l'échangeur de chaleur en faisant fonctionner ce dernier dans toute sa plage opératoire admissible. De ce fait, les variables retenues comme sorties du modèle flou à identifier sont :

- la température d'air à l'admission de l'échangeur (T_{16}),
- la température d'eau à la sortie de l'échangeur (T_{34}).

Les variables caractéristiques ou de décision sont :

- la température d'air à la sortie du dispositif de chauffe (T_{14}),
- la puissance de chauffe P_c ,
- la position de la vanne de recyclage d'air (V_a).




Figure 4.5 : Signaux d'identification appliqués à l'échangeur de chaleur.

Durant les essais, et pour des raisons de sécurité de l'installation, il nous a été recommandé de manipuler les électrovannes de recyclage et d'évacuation d'air de manière conjointe de telle sorte que l'on ait à tout instant :

$$\alpha_{21} + \alpha_{22} = 100\% \quad (4.12)$$

C'est pourquoi, nous utilisons uniquement la position de la vanne de recyclage d'air V_a comme variable de décision. Ainsi, le modèle flou proposé se compose de deux modèles flous TS ($\mathcal{M}1$) et ($\mathcal{M}2$) représentant chacun une fonction dynamique non linéaire de la forme :

$$(\mathcal{M}1) : T_{34} = f(T_{34}, T_{16}, P_c, V_a) \quad (4.13)$$

$$(\mathcal{M}2) : T_{16} = f(T_{16}, T_{14}, P_c, V_a) \quad (4.14)$$

Après plusieurs essais de réponses indicielles obtenues pour différentes amplitudes de P_c , on a fini par choisir des régresseurs d'ordre 1. Par conséquent, les variables de décision du modèle flou TS ($\mathcal{M}1$) sont données par le vecteur :

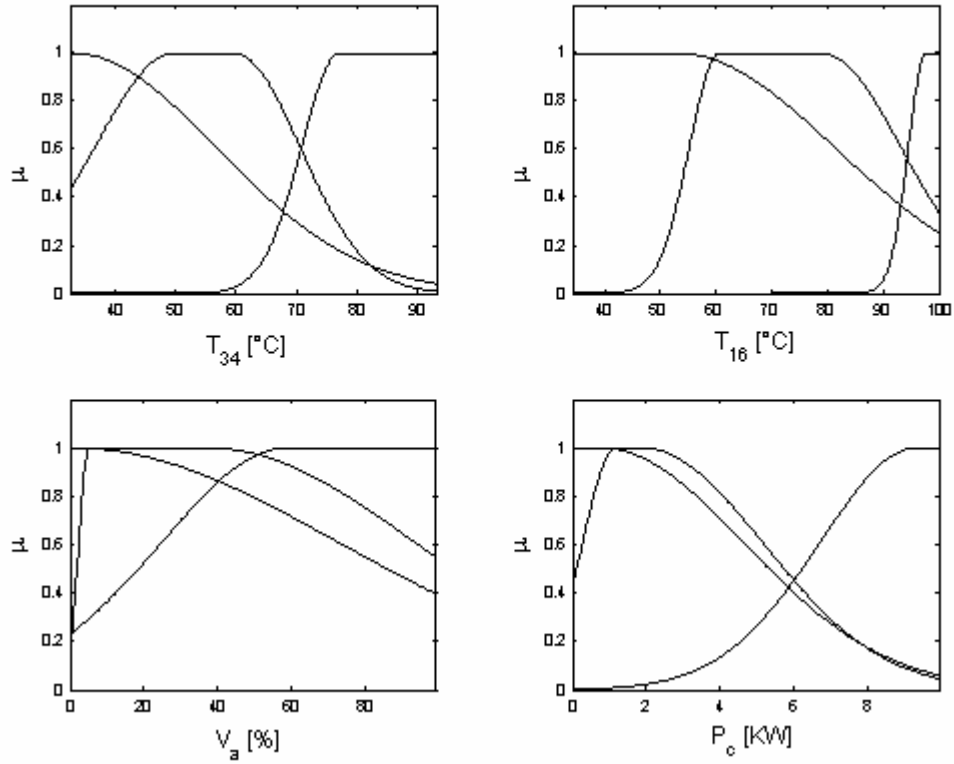


Figure 4.6 : Fonctions d'appartenance des variables de décision du modèle flou ($\mathcal{M1}$).

$$\mathbf{x}(k) = [T_{34}(k-1) \ T_{16}(k-1) \ P_c(k-1) \ V_a(k-1)]^T \quad (4.15)$$

et celles du modèle flou TS ($\mathcal{M2}$) par :

$$\mathbf{x}(k) = [T_{16}(k-1) \ T_{14}(k-1) \ P_c(k-1) \ V_a(k-1)]^T \quad (4.16)$$

En somme, la forme retenue de la i ème règle du modèle flou de l'échangeur de chaleur pilote s'exprime linguistiquement par :

Règle i :

$$\begin{aligned} (\mathcal{M1}) : & \text{ If } P_c(k) \text{ is } A_{11}^i \text{ and } V_a(k) \text{ is } A_{12}^i \text{ and } T_{16}(k) \text{ is } A_{13}^i \text{ and } T_{34}(k) \text{ is } A_{14}^i \\ & \text{ Then } T_{34}(k+1) = b_1^i + a_{11}^i P_c(k) + a_{12}^i V_a(k) + a_{13}^i T_{16}(k) + a_{14}^i T_{34}(k) \\ & \text{ Also} \\ (\mathcal{M2}) : & \text{ If } P_c(k) \text{ is } A_{21}^i \text{ and } V_a(k) \text{ is } A_{22}^i \text{ and } T_{14}(k) \text{ is } A_{23}^i \text{ and } T_{16}(k) \text{ is } A_{24}^i \\ & \text{ Then } T_{16}(k+1) = b_2^i + a_{21}^i P_c(k) + a_{22}^i V_a(k) + a_{23}^i T_{14}(k) + a_{24}^i T_{16}(k) \end{aligned} \quad (4.17)$$

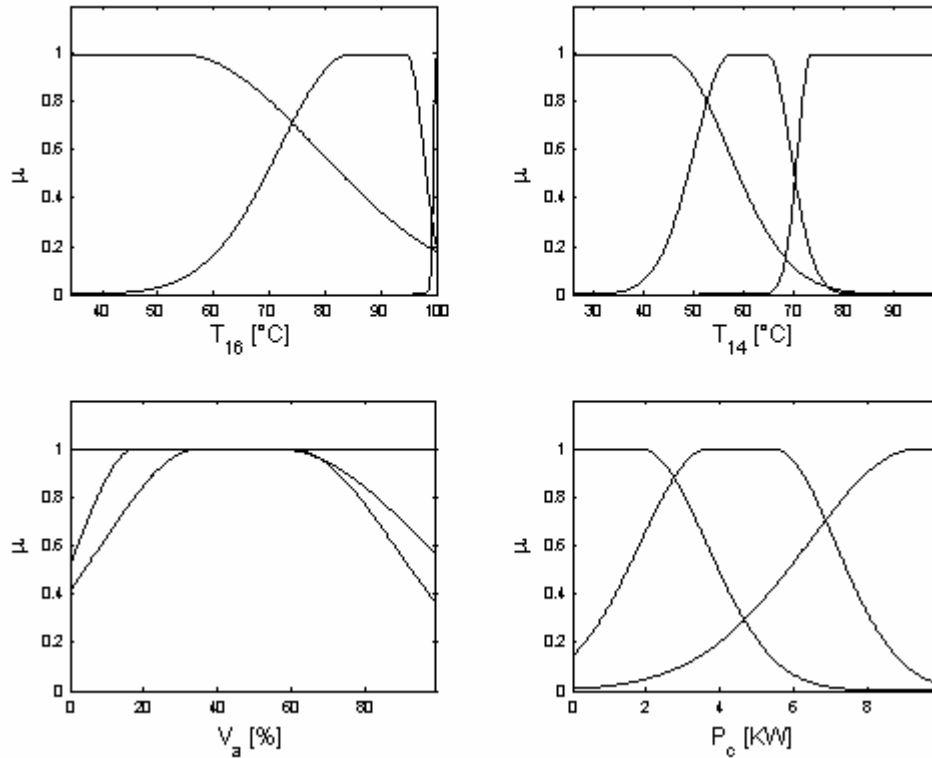


Figure 4.7 : Fonctions d'appartenance des variables de décision du modèle flou (\mathcal{M}_2).

Remarquons que le passé de chacune des sorties T_{16} et T_{34} figure en tant que variable de décision dans les prémisses des règles floues. Ainsi établi, le modèle flou (4.17) est alors un modèle dynamique à caractère globalement non linéaire (voir section 3.2 du chapitre 3).

Pour identifier les modèles flous TS (\mathcal{M}_1) et (\mathcal{M}_2), une campagne de $N = 2000$ mesures ont été prises pour chacune des variables de sortie à un pas $T_0 = 2s$. Durant ces essais, le débit d'eau est maintenu constant à environ $Q_e = 60$ l/h. La température d'eau en provenance du réservoir d'alimentation affichait $T_{33} = 25^\circ C$. Les variables excitatrices, à savoir la puissance de chauffe P_c et les positions des vannes de recyclage et d'évacuation d'air, sont manipulées de manière à couvrir l'ensemble de leurs domaines de variation admissibles. L'amplitude ainsi que la durée de maintien de ces excitations ont été modulées en tenant compte de l'ordre de grandeur de la constante de temps du circuit d'eau et celle du circuit d'air (voir annexe A). Les signaux d'excitation à lesquels était soumis l'échangeur de chaleur sont illustrés à la figure 4.5.




Figure 4.8 : Résultats d'identification de l'échangeur de chaleur obtenus à l'aide de l'algorithme de clustering GK.

4.1. Résultats expérimentaux d'identification

Les mesures entrées-sorties prélevées lors des essais d'identification sont tout d'abord arrangées de manière à permettre l'application de l'algorithme de clustering de Gustafson-Kessel (GK) décrit dans le chapitre 3. L'algorithme est appliqué hors ligne sur les données acquises et est initialisé avec les paramètres suivants : $\delta = 2$, $\varepsilon = 0.01$ et $c = 3$. Notons que le choix d'un nombre de clusters c supérieur à 3 n'améliore en rien la précision des modèles flous identifiés, mais plutôt complique leurs structures.

Ainsi, chaque modèle flou TS obtenu est composé de trois règles de type IF-THEN. Les domaines de variation des variables de décision sont partitionnés en trois zones caractérisant chacune une région de fonctionnement. Les partitions floues relatives au modèle flou (\mathcal{M}_1) sont données en figure 4.6, celles relatives au modèle flou (\mathcal{M}_2) sont illustrées à la figure 4.7. Les paramètres des modèles ARX locaux figurant dans les conditions des règles floues sont estimés à l'aide de l'approche OLS locale décrite dans la section 4.4 du chapitre 3. Les résultats d'estimation paramétrique sont indiqués dans les tableaux 4.1 et 4.2.

Tableau 4.1 : Paramètres du modèle flou TS ($\mathcal{M}1$).

Règle	Conclusion de la règle				
	a_{14}	a_{13}	a_{12}	a_{11}	b_1
1	0.9609	0.0233	-0.0033	0.0021	0.0569
2	0.9683	0.0127	0.0016	0.0034	0.0659
3	0.9768	0.0629	0.0045	0.0081	-0.5146

Tableau 4.2 : Paramètres du modèle flou TS ($\mathcal{M}2$).

Règle	Conclusion de la règle				
	a_{24}	a_{23}	a_{22}	a_{21}	b_2
1	0.7390	0.3117	0.0065	0.0554	0.0862
2	0.7068	0.3135	0.0080	0.0469	0.4374
3	0.8825	0.0020	-0.0004	0.0002	1.1580

Les sorties de l'échangeur de chaleur et celles du modèle flou résultant de l'algorithme de clustering GK sont données en figure 4.8. Cette approximation est réalisée à partir d'un ensemble fini de données en présence de bruits. Afin d'évaluer sa qualité, nous utilisons l'indice de performance VAF (*Variance Accounted For*) basé sur le calcul du taux de variance entre les sorties mesurées et les sorties estimées par le modèle flou. L'indice VAF est calculé à l'aide de l'expression suivante :

$$VAF = 100\% \cdot \left[1 - \frac{\text{var}(y - \hat{y})}{\text{var}(y)} \right] \quad (4.18)$$

où y désigne la sortie du processus, \hat{y} la sortie du modèle et $\text{var}(\cdot)$ la variance du signal.

L'erreur de prédiction estimée en terme de VAF est évaluée à 99,9925% pour la température d'eau T_{34} et à 99,9633% pour la température d'air T_{16} . D'après la figure 4.8, il apparaît clairement que les signaux d'excitation appliqués à l'échangeur de chaleur étaient bien suffisants pour faire fonctionner l'échangeur de chaleur dans toute sa plage opératoire conformément aux objectifs désirés. En effet, la température d'eau a presque atteint sa limite maximale au cours de son évolution alors que la température d'air T_{16} s'est saturée à maintes reprises sous l'effet des excitations manipulées. Remarquons que, dans cette situation même, le modèle flou identifié n'échoue pas à réaliser une bonne approximation de la variable de sortie en question.




Figure 4.9 : Validation hors ligne du modèle flou proposé.

Enfin, il convient de noter qu'il est possible de réduire davantage la structure du modèle flou obtenu à l'aide d'une approche appropriée [ZHA 94]. Cet aspect n'étant pas développé dans ce chapitre car, dans les essais réalisés, nous n'avons pas tenu compte d'une éventuelle simplification des modèles flous TS. Des explications supplémentaires à ce sujet sont données en annexe C.

4.2. Validation du modèle flou proposé

Selon la manière dont l'erreur de prédiction est générée, deux configurations distinctes ont été considérées dans la phase de validation : la première, dite parallèle et désignée par "sortie du modèle par simulation" dans le chapitre 3 (section 2.1.1), fait usage de la sortie du modèle flou identifié, ce qui donne pour le modèle (\mathcal{M}) :

$$\hat{T}_{34}(k+1) = f(\hat{T}_{34}(k), T_{16}(k), P_c(k), V_a(k)) \quad (4.19)$$




Figure 4.10 : Validation en ligne du modèle flou proposé.

La deuxième configuration, dite série-parallèle et désignée par "sortie du modèle par prédiction" dans le même chapitre, fait intervenir la sortie du processus mesurée, c'est-à-dire :

$$\hat{T}_{34}(k+1) = f(T_{34}(k), T_{16}(k), P_c(k), V_a(k)) \quad (4.20)$$

Dans un premier test de validation, nous avons simulé les sorties du modèle flou identifié en utilisant les mêmes signaux d'excitation qui ont été appliqués à l'échangeur de chaleur lors des essais d'identification (Fig. 4.5). Ce test est réalisé hors ligne et fait usage des données expérimentales d'identification à lesquelles sont comparées les sorties T_{34} et T_{16} du modèle flou obtenues par simulation. Les résultats de ce test sont donnés en figure 4.9. Cette figure montre clairement l'aptitude du modèle flou proposé à reproduire de manière efficace les évolutions des températures d'eau et d'air enregistrées dans la phase d'identification. Pour la prédiction de la température T_{34} , l'erreur moyenne (MSE), évaluée selon la configuration parallèle (4.19), est de l'ordre de 0,0421, celle de prédiction de la température T_{16} est 0,0097. Ces résultats affichent

une très grande satisfaction et laissent prévoir une très bonne approximation dans le test de validation en ligne comme nous le verrons dans la suite.

En fait, pour valider en ligne le modèle flou proposé, nous avons utilisé des signaux d'excitation différents de ceux employés dans les essais d'identification. Pour ce faire, les vannes de recyclage et d'évacuation d'air sont simultanément commandées dans la plage de variation allant de 0 à 50% et la puissance de chauffe dans la plage 0-5 KW. La température d'eau parcourant la conduite d'alimentation affichait initialement 20°C, soit 5°C moins par rapport aux données d'identification, et le débit d'eau $Q_e = 451/h$.

Les résultats de ce test sont donnés en figure 4.10. Cette figure illustre l'évolution des températures de sortie de l'échangeur de chaleur et celles estimées par le modèle flou. Les erreurs moyennes de prédiction calculées pour les deux sorties estimées sont très proches de zéro, ce qui justifie encore une fois la capacité d'approximation et de généralisation du modèle flou TS proposé, surtout en présence des bruits de mesure dans les données. Le tableau 4.3 donne une évaluation globale de la performance du modèle flou proposé pour l'ensemble des essais de validation réalisés.

Tableau 4.3 : Performance du modèle flou proposé (MSE).

Modèle flou TS	Modèles locaux	Validation hors ligne		Validation en ligne	
		p	s	p	s
T_{34}	3	0,0421	0,0001	0,0292	$8,2810.10^{-5}$
T_{16}	3	0,0097	0,0013	0,0087	$9,4483.10^{-4}$

$p \rightarrow$ configuration parallèle, $s \rightarrow$ configuration série-parallèle.

5. Conception du système de surveillance

Dans cette section, nous traitons le problème particulier de la détection et le diagnostic des défauts dans l'échangeur de chaleur en se basant sur le modèle flou établi dans la section précédente. Pour la conception et la mise en œuvre d'un tel système de surveillance, nous nous sommes basés sur la démarche de synthèse présentée dans la section 5 du chapitre 3. Le problème de surveillance étant considéré par ses trois principaux aspects, à savoir la détection de défauts, l'isolation de défauts et la prise de décision.

En pratique, l'échangeur de chaleur peut être affecté par différents types de défauts. Dans les tests expérimentaux, nous avons considéré des défauts d'actionneurs, de capteurs et de fuite d'eau. Les deux premiers types sont classés dans la catégorie des défauts abrupts, le troisième type dans la catégorie des défauts graduels. Les principaux modes de défaillance examinés sont les suivants :

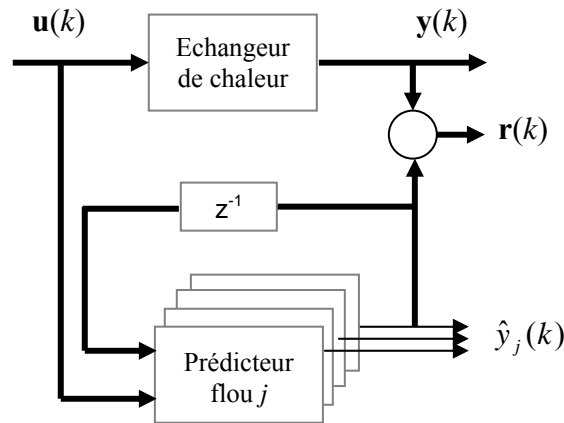


Figure 4.11 : Schéma de détection et d'isolation des défauts appliqué à l'échangeur de chaleur.

- f_ϕ fuite dans la conduite d'eau alimentant l'échangeur de chaleur,
- $f_{T_{34}}$ défaut du capteur de température d'eau T_{34} ,
- $f_{T_{16}}$ défaut du capteur de température d'air T_{16} ,
- f_P défaut dans le dispositif de chauffe,
- f_{V_a} blocage de la vanne de recyclage d'air.

5.1. Conception du générateur de résidus

Comme il a été souligné dans la section 4, le modèle flou de l'échangeur de chaleur résulte de la composition des deux modèles flous TS ($\mathcal{M}1$) et ($\mathcal{M}2$). Ainsi, pour le besoin de détection des défauts, deux résidus $r_{T_{34}}$ et $r_{T_{16}}$ sont générés. Ces résidus sont obtenus en comparant les sorties mesurées du processus surveillé $\mathbf{y}(k) = [T_{34}(k) T_{16}(k)]^T$ et les sorties estimées par le modèle flou proposé $\hat{\mathbf{y}}(k) = [\hat{T}_{34}(k) \hat{T}_{16}(k)]^T$.

La génération des signaux $r_{T_{34}}$ et $r_{T_{16}}$ est suffisante pour mettre en évidence la présence de défauts dans l'échangeur de chaleur. Néanmoins, la seule information issue du modèle flou identifié en régime de fonctionnement sain est loin d'être suffisante pour le besoin d'isolation de ces défauts. Ainsi, pour pouvoir détecter et isoler simultanément les défauts survenus, nous avons envisagé d'exploiter la redondance analytique exprimée explicitement dans le modèle flou identifié.

L'idée consiste à construire des prédicteurs flous représentés par des modèles flous TS en se servant des mesures entrées-sorties acquises en mode de fonctionnement sain

(non défaillant). Ces prédicteurs emploient des variables de décision différentes choisies de telle façon à permettre la génération de résidus structurés. En plus des modèles flous TS ($\mathcal{M}1$) et ($\mathcal{M}2$), quatre autres prédicteurs flous sont identifiés à l'aide de l'algorithme de clustering GK à partir des mesures entrées-sorties utilisées dans la phase d'identification de l'échangeur de chaleur. La structure des prédicteurs flous identifiés et leur performance exprimée en termes d'erreurs moyennes MSE sont résumées dans le tableau 4.4.

Sur la base de l'ensemble des prédicteurs flous établis, six résidus de détection $r_j, j = 1, \dots, 6$, sont générés selon la configuration schématisée par la figure 4.11. Ces indicateurs d'anomalies sont obtenus par :

$$r_j = y - \hat{y}_j \quad (4.21)$$

où y est la sortie du processus (T_{34} ou T_{16}) et \hat{y}_j la sortie du prédicteur flou (\hat{T}_{34} ou \hat{T}_{16}). Ainsi obtenus, les résidus peuvent être affectés par un ou plusieurs défauts comme l'indique le tableau 5, appelé aussi matrice d'incidence. Dans cette matrice, un "1" désigne la sensibilité du résidu au défaut, et un "0" reflète l'insensibilité du résidu au défaut.

A première vue, il est facile de constater q'un tel arrangement permet bien d'isoler les défauts $f_{T_{16}}, f_p$ et f_{V_a} survenant séparément sur l'échangeur de chaleur. Cependant, les défauts $f_{T_{34}}$ et f_ϕ ont une faible probabilité d'être isolés systématiquement car tous les deux affectent simultanément les résidus r_1, r_2, r_3 et r_4 . Dans ce cas précis, il convient de noter que le défaut f_ϕ provoque uniquement des changements positifs dans la moyenne des résidus, se traduisant par une augmentation de la température d'eau T_{34} , alors que le défaut $f_{T_{34}}$ en engendre des changements dans les deux sens (positif et négatif). Une fois localisé, cette spécificité servirait bien à la détermination de la nature du défaut ayant effectivement affecté la température T_{34} .

Tableau 4.4 : Structure et performance des prédicteurs flous.

Prédicteur flou	Structure	Modèles locaux	Performance (MSE)	Moyenne du résidu
1	$T_{34} = f(T_{34}, T_{16}, P_c, V_a)$	3	0,0421	0,0079
2	$T_{34} = f(T_{34}, T_{14}, P_c, V_a)$	3	0,0184	0,0043
3	$T_{34} = f(T_{34}, T_{16}, P_c)$	3	0,0636	0,0063
4	$T_{34} = f(T_{34}, T_{16}, V_a)$	3	0,1023	0,0085
5	$T_{16} = f(T_{16}, T_{14}, P_c, V_a)$	3	0,0097	$2,4995.10^{-4}$
6	$T_{16} = f(T_{16}, T_{14}, P_c)$	3	0,0122	$8,2269.10^{-4}$

Tableau 4.5 : Matrice d'incidence.

Résidu	$f_{T_{34}}$	$f_{T_{16}}$	f_P	f_{V_a}	f_ϕ
r_1	1	1	1	1	1
r_2	1	0	1	1	1
r_3	1	1	1	0	1
r_4	1	1	0	1	1
r_5	0	1	1	1	0
r_6	0	1	1	0	0

5.2. Test expérimental du générateur de résidus

• Validation en présence d'une fuite d'eau :

Lors de la validation en ligne du système de diagnostic, nous avons accordé une attention particulière au problème de fuite d'eau dans l'échangeur de chaleur. Ce problème étant assez fréquent en milieu industriel et suscite souvent un intérêt particulier vu les incidences graves d'une telle dégradation. Le plan d'instrumentation de l'échangeur de chaleur pilote offre la possibilité de créer des fuites d'eau avec des amplitudes variant entre 0 et 80 litres/heure à l'aide d'une vanne placée sur la conduite d'alimentation en eau (voir Fig. 4.12).

Dans un premier test de validation, nous avons commencé par analyser la sensibilité du système de surveillance à ce type de défaut. Pour ce faire, différents taux de fuite d'eau ont été considérés. Les principaux essais réalisés dans ce test se résument aux cas suivants :

- **Cas 1** : $f_\phi = 15\%$ introduit à $k = 525$, $0 \leq P_c \leq 7$ KW, $k \in [0 \ 1000]$.
- **Cas 2** : $f_\phi = 25\%$ introduit à $k = 950$, $0 \leq P_c \leq 10$ KW, $k \in [0 \ 2000]$.
- **Cas 3** : $f_\phi = 30\%$ introduit à $k = 610$, $0 \leq P_c \leq 10$ KW, $k \in [0 \ 1500]$.
- **Cas 4** : $f_\phi = 40\%$ introduit à $k = 290$, $0 \leq P_c \leq 5$ KW, $k \in [0 \ 1000]$.

Pour des raisons de sécurité de l'installation, il a été nécessaire d'adapter le domaine de variation de la puissance de chauffe appliquée à l'échangeur de chaleur aux conditions propres à chaque essai en tenant compte de l'amplitude de la fuite d'eau introduite dans chaque cas. Cette considération est d'ordre technique et ne traduit en aucun cas une forme de dépendance entre les amplitudes des grandeurs manipulées.


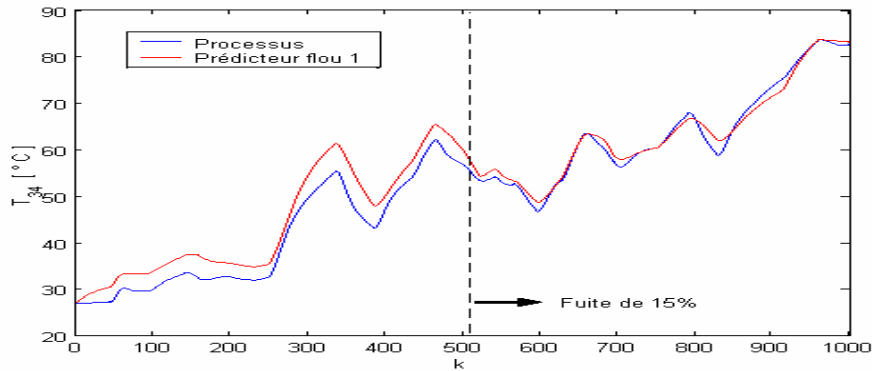


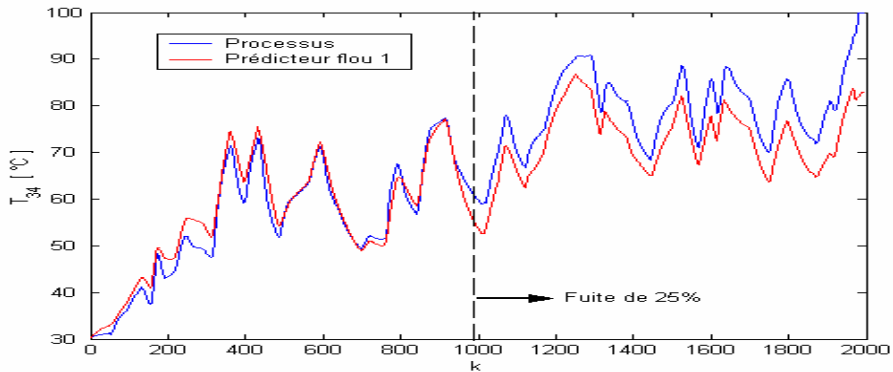
Figure 4. 12 : Emplacement de la fuite d'eau dans la conduite d'alimentation de l'échangeur de chaleur.

Les figures 4.13 et 4.14 illustrent l'évolution de la température d'eau T_{34} et son estimée \hat{T}_{34} obtenues pour l'ensemble des cas envisagés. Notons que pour le cas 2 (fuite d'eau relativement faible), la puissance de chauffe étant manipulée sur toute sa plage opératoire avec un temps de maintien maximum de 200 s, ce qui s'est traduit par une augmentation significative de la température T_{34} jusqu'à atteindre les 100°C. La même plage de variation est considérée dans le cas 3 mais en réduisant de moitié la durée de maintien des excitations, c'est-à-dire à 100 s maximum. Dans le cas 4, il a été nécessaire d'opter pour une excitation en puissance allant de 0 à 5 KW, car une fuite de 40% allait provoquer rapidement l'augmentation de T_{34} sous l'effet des excitations manipulées dans les cas 2 et 3.

Pour compléter l'analyse, nous présentons dans le tableau 4.6 l'évolution de l'ensemble des résidus résultant pour différentes amplitudes de la fuite d'eau f_{ϕ} . Les résultats expérimentaux obtenus montrent clairement les déviations significatives des résidus r_1 , r_2 , r_3 et r_4 , ce qui traduit la sensibilité du système de surveillance à ce type de défaut. Cependant, la déviation dans le cas 1 n'est pas nettement visible comme il peut être déduit de la figure 4.13. Sous certaines réserves, nous pouvons alors considéré le taux de fuite de 15%, soit 12 litres/h, comme étant l'amplitude minimale de fuite que puisse détecter notre système de surveillance. Toutefois, avec un nombre de mesures plus grand (2000 échantillons par exemple), nous aurions pu faire une conclusion plus précise quant au seuil minimum détectable de f_{ϕ} .



(Cas 1)



(Cas 2)

Figure 4.13 : Test expérimental du générateur de résidus pour différentes amplitudes de f_{θ} .

En choisissant d'introduire la fuite d'eau dans la phase de transition des résidus, c'est-à-dire avant leur établissement final à environ zéro, nous avons pu obtenir des résultats intéressants. Les cas 3 et 4 représentent les essais réalisés dans ce sens. Remarquons que la déviation des résidus r_1 , r_2 , r_3 et r_4 est nettement visible dans ces deux cas, mettant en évidence la présence d'une fuite dans la conduite d'eau. Aussi, il convient de noter le changement dans la variance des résidus r_5 et r_6 résultants de l'essai correspondant au cas 3. Ces résidus doivent naturellement rester insensibles à ce type de défaut. Néanmoins, il n'est guère étonnant d'enregistrer un tel phénomène, car il ne s'agit pas d'une anomalie détectée mais plutôt de la saturation de la température d'air T_{16} qui avait atteint à plusieurs reprises sa valeur limite sous l'effet des excitations appliquées durant les essais.

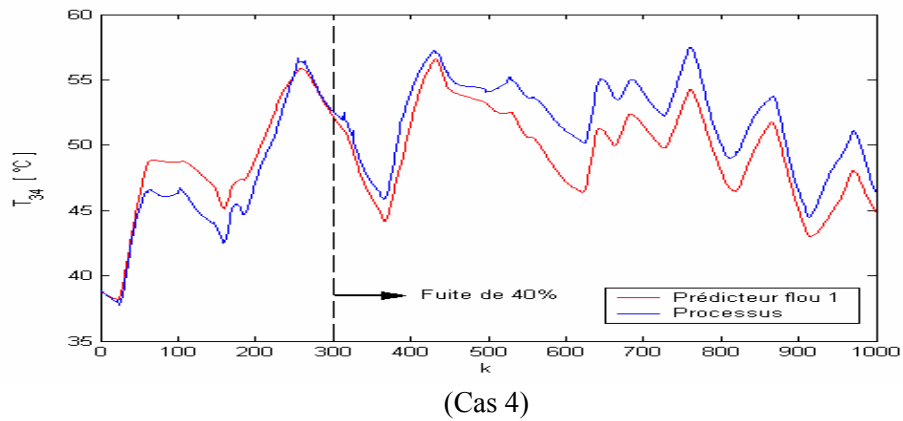



Figure 4.14 : Test expérimental du générateur de résidus pour différentes amplitudes de f_{θ} .

- **Validation en présence des défauts de capteurs et d'actionneurs :**

Pour simuler les défauts de capteurs, des offsets de 1, 2 et 4°C ont été rajoutés aux valeurs mesurées de T_{16} et T_{34} à différents instants. La figure 4.15 illustre l'évolution du résidu r_5 issu du prédicteur flou 5 pour $f_{T_{16}} = 1^{\circ}C$ et $f_{T_{16}} = 2^{\circ}C$ supposés survenir à $t = 2000s$. Quoiqu'il est difficile d'observer la sensibilité du résidu r_5 à ce défaut dans le premier cas ($f_{T_{16}} = 1^{\circ}C$) en raison des bruits de mesure, une évaluation du changement dans la moyenne de r_5 suffirait pour décider de l'occurrence du défaut. En fait, la moyenne de r_5 est passée de 0,0283, pour $t \leq 2000s$, à 0,2278, pour $t > 2000s$, soit un changement positif d'environ 0,2.

Le tableau 4.7 résume les résultats obtenus dans les autres cas envisagés.




Figure 4.15 : Résidus issus du prédicteur flou 5 pour $f_{T_{16}} = 1^\circ\text{C}$ et $f_{T_{16}} = 2^\circ\text{C}$.

A titre d'exemple, considérons le cas d'un défaut d'amplitude $+4^\circ\text{C}$ supposé survenir sur le capteur de température d'eau à $t = 3000\text{ s}$. Le changement dans la moyenne des résidus r_1 et r_2 est nettement significatif. De même, les résidus r_3 et r_6 ont considérablement dévié de leurs valeurs moyennes après avoir introduit un défaut de $+4^\circ\text{C}$ dans le capteur de température d'air T_{16} à $t = 2000\text{ s}$. D'autre part, on s'est intéressé à certains défauts pouvant affecter les actionneurs de l'échangeur de chaleur. Les modes de défaillance envisagés sont les suivants : défaillance du système de commande de la puissance de chauffe et le blocage de la vanne de recyclage d'air. Les résultats obtenus dans ces deux cas sont aussi représentés dans le tableau 4.7.

Enfin, il convient de noter que pour l'ensemble des cas traités, les changements dus à des défauts de capteurs et d'actionneurs de faibles amplitudes ($|f_y| < 1^\circ\text{C}$ pour les températures et $|f_u| < 1\text{ v}$ pour la tension de déphasage) n'apparaissent pas clairement sur les courbes d'évolution des résidus vu la présence de bruits dans les mesures, ce qui nécessite l'utilisation d'un formalisme particulier de détection de changements pour mettre en évidence ces anomalies. Le problème de détection de changements et de génération de symptômes analytiques est abordé dans la section suivante.

Tableau 4.6 : Résidus de détection résultants pour différentes amplitudes du défaut f_ϕ (fuite d'eau).

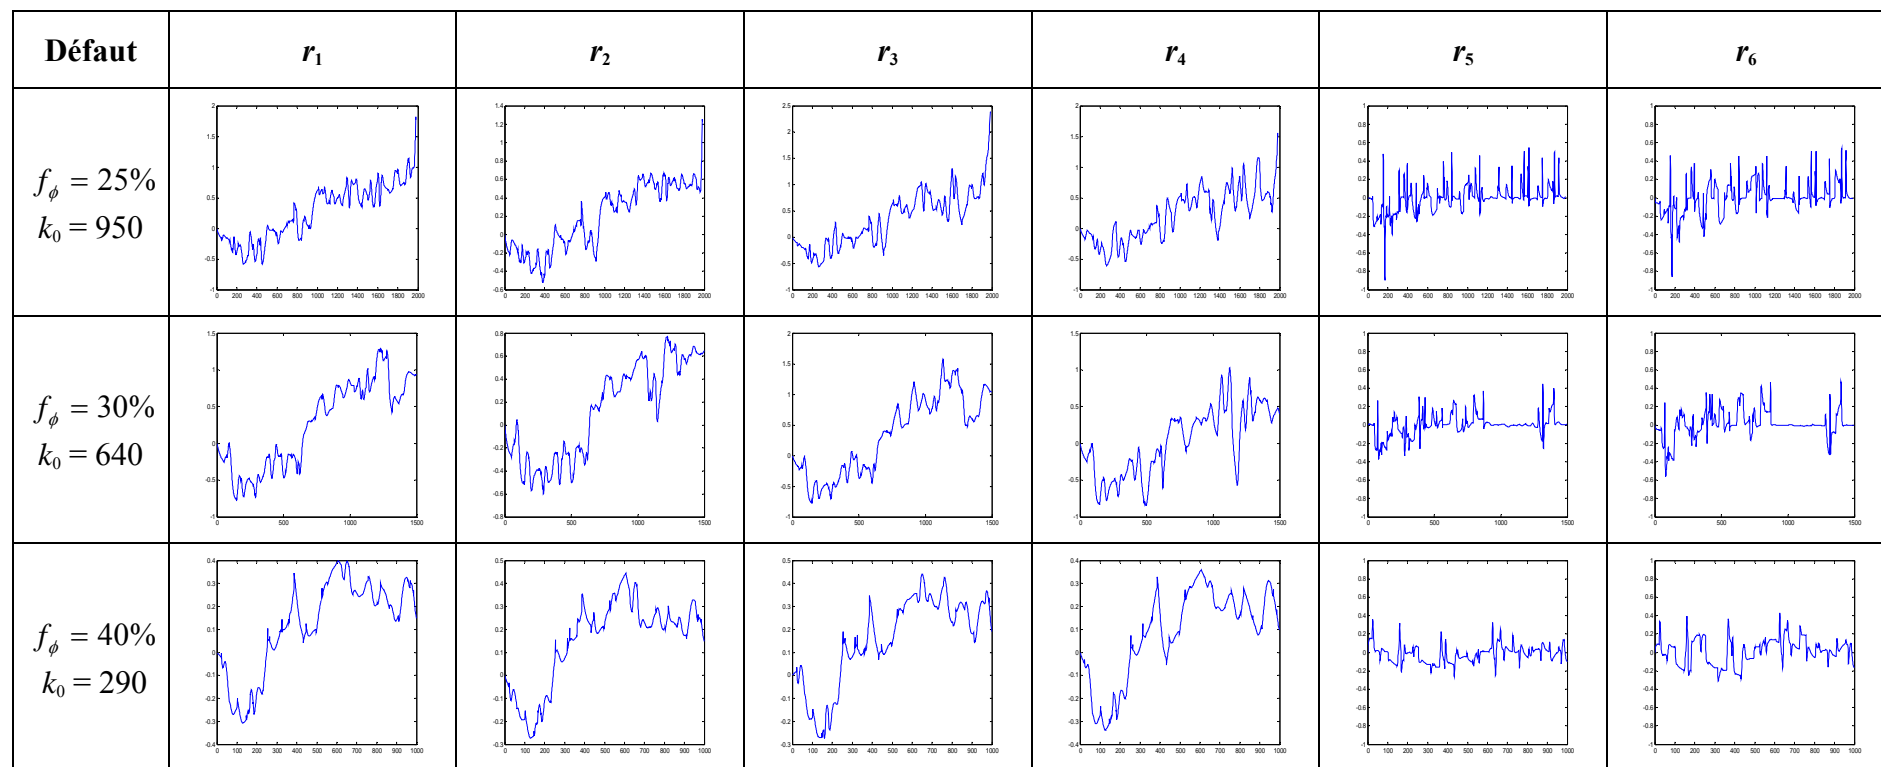
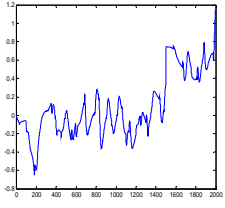
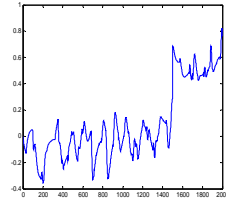
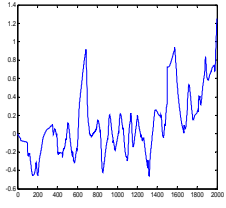
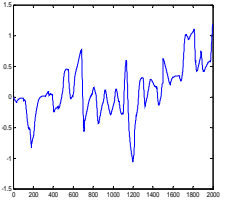
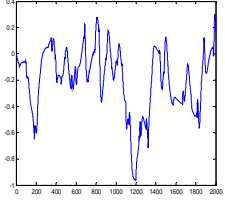
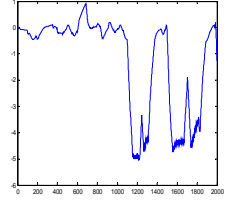
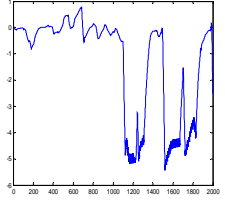
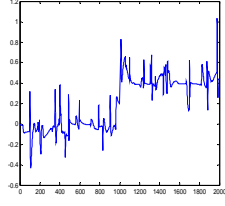
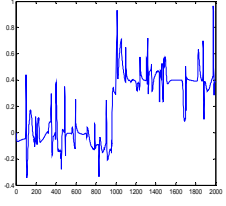
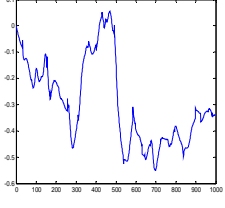
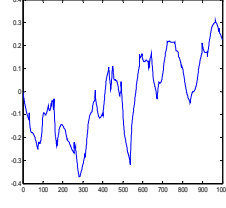
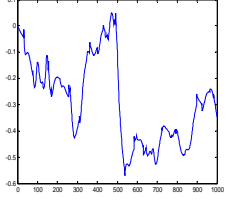
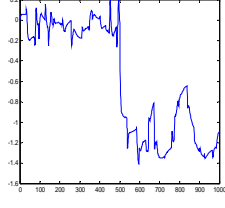
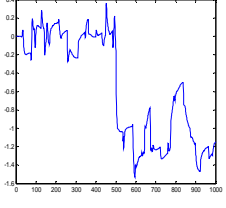
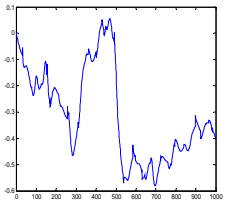
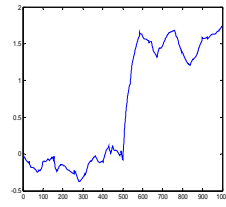
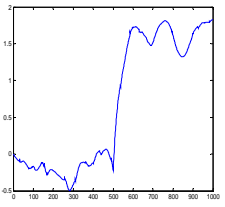
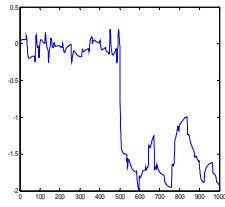


Tableau 4.7 : Résidus de détection résultants pour différentes amplitudes des défauts de capteurs et d'actionneurs.

Défaut	r_1	r_2	r_3	r_4	r_5	r_6
$f_{T_{34}} = 4^\circ C$ $k_0 = 1500$					0	0
$f_{T_{16}} = 4^\circ C$ $k_0 = 1000$		0				
$f_P = 5 KW$ $k_0 = 500$				0		
$f_{V_a} = 100\%$ $k_0 = 500$			0			0

5.3. Implémentation de l'algorithme CUSUM et évaluation des résidus

Dans cette phase, les résidus générés dans l'étape précédente sont analysés pour décider de la présence ou non du défaut et déterminer sa taille et l'instant de son occurrence. L'emploi d'un simple seuillage a moins de chance d'être satisfaisant pour l'ensemble des défauts envisagés car, d'une part, l'amplitude de certains défauts est faible et le rapport signal-bruit est trop petit, d'autre part, la dégradation provoquée par une fuite d'eau est lente (défaut graduel), ce qui nécessite l'emploi d'un formalisme approprié pour la prise de décision, surtout que l'échangeur de chaleur opère dans un environnement entièrement stochastique.

Pour ce faire, l'algorithme récurrent de somme cumulée (CUSUM), décrit dans la section 5.2.1 du chapitre 3, est implémenté et validé pour l'ensemble des défauts considérés. Notons que c'est la formulation vectorielle du CUSUM (Annexe B) qui a été utilisée car, d'un point de vue pratique, il est nécessaire de traiter de façon globale l'ensemble des signaux de détection et d'établir une décision qui dépend de l'évolution de l'ensemble de ces signaux.

Plus précisément, considérons le vecteur résiduel $\mathbf{r}(k)$ formé des observations issues des six prédicteurs flous, *i.e.*

$$\mathbf{r}(k) = [r_1(k) \ r_2(k) \ r_3(k) \ r_4(k) \ r_5(k) \ r_6(k)]^T \quad (4.22)$$

La moyenne $\hat{\mathbf{v}}_0$ et la variance $\hat{\Sigma}$ du vecteur résiduel $\mathbf{r}(k)$ sont estimées à partir des signaux mesurés en mode de fonctionnement sain de l'échangeur de chaleur. Elles sont données par :

$$\hat{\mathbf{v}}_0 = [0,0079 \quad 0,0043 \quad 0,0063 \quad 0,0085 \quad 0,0002 \quad 0,0008]^T$$

$$\hat{\Sigma} = \begin{bmatrix} 0,0421 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0,0184 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0,0636 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0,1022 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0,0097 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0,01222 \end{bmatrix}$$

L'idée consiste à détecter et à diagnostiquer les changements dans la moyenne du vecteur résiduel $\mathbf{r}(k)$ engendrés séparément par différentes amplitudes des défauts $f_{T_{16}}$, $f_{T_{34}}$, f_P , f_{V_a} et f_ϕ , survenant séparément à différents instants. Pour la mise en œuvre de l'algorithme CUSUM, il est nécessaire de connaître l'amplitude \mathbf{v}_1 des changements que l'on désire détecter. Ce paramètre de conception dépend généralement




Figure 4.16 : Variations du délai moyen de détection $\hat{\tau}$ et du temps moyen entre les fausses alarmes $\hat{\kappa}$ obtenues pour $f_o = 25\%$.

de la nature du défaut à détecter. Pour le cas de la fuite d'eau, l'amplitude des changements est déduite à partir des différents essais réalisés sur l'installation. En effet, les déviations observées, dans ce cas, concernent uniquement les résidus r_1, r_2, r_3 et r_4 avec un changement d'environ $+4^\circ\text{C}$ dans leurs moyennes. Alors que pour les défauts de capteurs et d'actionneurs, \mathbf{v}_1 est choisi selon l'amplitude minimale que l'on souhaite détecter. Elle est fixée à $\pm 1^\circ\text{C}$ pour les capteurs et ± 1 volt pour les actionneurs.

Un autre paramètre important à choisir est le seuil de décision h . Le choix de h résulte généralement d'un compromis entre la probabilité de fausses alarmes et le temps de retard à la détection souhaités. Ces deux facteurs sont évalués à l'aide de la fonction ARL donnée par l'équation (3.52). Nous exposons dans la suite les résultats obtenus dans chacun des cas.

• **Résultats obtenus :**

Considérons tout d'abord le problème de fuite d'eau. Dans le premier cas, une fuite de 20 l/h est supposée survenir à l'instant $k = 950$ (exprimé en nombre d'échantillons). Comme le montre le tableau 4.6, les résidus affectés par ce type de défaut sont r_1, r_2, r_3 et r_4 . Les résidus r_5, r_6 restent cependant insensibles à ce défaut. Pour $k > 950$, les changements enregistrés dans la moyenne des résidus sont comme suit :




Figure 4.17 : Fonctions de somme cumulée $S(k)$ et de décision $g(k)$ résultants de l'algorithme récurrent CUSUM pour $f_0 = 25\%$.




Figure 4.18 : Zoom au voisinage de $k = 950$ sur la fonction de décision $g(k)$ résultant du CUSUM pour $f_0 = 25\%$.

$$|\Delta \mathbf{v}| = [0,5445 \quad 0,3834 \quad 0,6659 \quad 0,4329 \quad 0,0207 \quad 0,0138]^T$$

Une estimation de la moyenne et de la variance de la somme cumulée (3.44) donne :

$$v_s = 4,3862 \quad \text{et} \quad \sigma_s^2 = 8,7725$$

En reportant ces valeurs dans l'expression de la fonction ARL, on aboutit aux allures représentées dans la figure 4.16 illustrant la variation du délai moyen de détection $\hat{\tau}$ et du temps moyen entre les fausses alarmes $\hat{\kappa}$ en fonction du seuil de décision h . D'après

cette figure, un seuil $h = 35$ assure un temps moyen entre les fausses alarmes supérieur à 10^{10} et un délai moyen de détection inférieur à 10, soit 20 secondes.

L'algorithme CUSUM étant initialisé avec ces paramètres et appliqué aux données expérimentales acquises sur l'horizon de temps $[0 \ 2000]$. L'évolution de la fonction de somme cumulée $S(k)$ et celle de la fonction de décision $g(k)$ résultant de l'algorithme récurent sont représentées à la figure 4.17. Le test du rapport de vraisemblance fournit dans ce cas une alarme à l'instant $k_a = 970$. L'instant d'occurrence de la fuite d'eau étant estimé à $\hat{k}_0 = 956$, soit un retard à la détection d'environ 12 secondes par rapport à l'instant d'occurrence effectif.

Ces mêmes paramètres ont été employés pour évaluer les résidus résultants pour $f_\phi = 30\%$ et $f_\phi = 40\%$ introduits respectivement à $k = 640$ et $k = 290$. Les résultats obtenus dans ces deux cas sont indiqués dans le tableau 4.8. Remarquons que dans le cas d'une fuite de 40%, une fausse alarme est générée à l'instant $k = 263$. Cette situation a nécessité la réévaluation du seuil de décision h . Après plusieurs simulations, nous avons opté pour $h = 50$. En conséquence, le délai de détection k_a est prolongé de 8 secondes pour $f_\phi = 25\%$, alors que l'instant d'occurrence du défaut reste inchangé comme le montre le tableau 4.9. Par ailleurs, aucune fausse alarme n'est enregistrée dans ce cas.

Tableau 4.8 : Résultats d'application du CUSUM pour $h = 35$ (fuite d'eau).

f_ϕ	Instant d'occurrence	k_a	Retard à la détection [s]	Fausse alarme
25%	950	970	40	0
30%	640	646	12	0
40%	290	263	–	1

Tableau 4.9 : Résultats d'application du CUSUM pour $h = 50$ (fuite d'eau).

f_ϕ	Instant d'occurrence	k_a	Retard à la détection [s]	Fausse alarme
25%	950	974	48	0
30%	640	647	14	0
40%	290	312	44	0

Tableau 4.10 : Résultats d'application du CUSUM pour $h = 50$: défauts de capteurs et d'actionneurs.

Défaut	Amplitude	Instant d'occurrence	k_a	\hat{k}_0	Retard à la détection [s]	fausse alarme
$f_{T_{34}}$	1°C	1500	1504	1486	8	0
	2°C	1500	1503	1489	6	0
	4°C	1500	1502	1489	4	0
$f_{T_{16}}$	1°C	1500	1529	1520	58	0
	2°C	1000	1012	1000	24	0
	4°C	1000	1007	1000	14	0
f_P	1 KW	650	667	652	34	0
	2 KW	500	507	502	14	0
	5 KW	500	505	503	10	0
f_{V_a}	1%	500	550	541	100	0
	100%	500	510	507	20	0

En procédant de la même manière et avec les paramètres du CUSUM établis dans ce qui précède, nous avons procédé à l'évaluation des résidus générés par l'ensemble des prédicteurs flous dans le cas des défauts de capteurs et d'actionneurs. Le tableau 4.10 résume les résultats obtenus pour différentes amplitudes des défauts $f_{T_{16}}$, $f_{T_{34}}$, f_P et f_{V_a} introduits séparément et à différents instants avec un seuil de décision $h = 50$. Il convient de noter que ces résultats peuvent être améliorés si h est choisi dans l'intervalle [30 45]. Cela entraîne, en contre partie, une augmentation de la probabilité de fausses alarmes si le processus se trouve affecté par un autre type de défaut (une fuite d'eau de 40% par exemple). De plus, le choix d'un seuil supérieur à 50 n'affecte en rien la robustesse du CUSUM, mais prolonge le délai de détection.

6. Conclusions

Ce chapitre est dédié à l'étude expérimentale que nous avons menée dans le cadre de ce projet de thèse. Les algorithmes d'identification et de surveillance présentés dans le chapitre 3 ont été implémentés et validés sur une installation pilote. L'échangeur de chaleur est l'élément principal de cette installation, les autres éléments constitutifs sont aussi considérés. Une procédure complète de synthèse pour la détection et l'isolation des défauts de capteurs, d'actionneurs et de fuite a été décrite. La détection et l'isolation des défauts sont simultanément réalisées par un système de génération de résidus impliquant six prédicteurs flous identifiés à partir de données expérimentales acquises lors des essais d'identification. Pour le besoin de prise de décision, une procédure d'évaluation optimale basée sur le test du rapport de vraisemblance est utilisée. Nous avons utilisé l'algorithme récurrent de somme cumulée CUSUM pour implémenter en

ligne cette procédure d'évaluation qui est formulée dans un cadre purement statistique. La méthode de surveillance employée dans cette étude ne nécessite pas un de modèle de connaissance physique du processus puisque les relations de transfert entrées-sorties sont déterminées par identification. Les résultats expérimentaux obtenus sont dans l'ensemble satisfaisants et donnent une justification de plus à l'applicabilité de l'approche floue en milieu industriel, notamment pour la résolution des problèmes de modélisation et de surveillance de processus complexes.

Conclusions et perspectives

A travers cette thèse, nous nous sommes fixés l'objectif de présenter et valider une approche d'identification et de surveillance pour les processus dynamiques complexes se basant sur la logique floue. Par souci d'applications industrielles, l'accent a été exclusivement mis sur des systèmes non linéaires. Les systèmes non linéaires étant beaucoup plus difficiles à analyser que les systèmes linéaires, leur identification et surveillance sont loin d'être aussi mûres et complètes. En général, la surveillance est étroitement liée à l'identification. D'une part, la surveillance est effectuée par rapport à un modèle de référence obtenu par identification, et la conception de l'algorithme de surveillance est souvent inspirée par l'algorithme d'identification. D'autre part, le modèle identifié doit être suffisamment représentatif et moins conservatif pour permettre la détection et le diagnostic des défauts considérés, et assez flexible que possible pour ne pas nuire à la conception et l'implémentation de l'algorithme de surveillance.

Notre contribution s'inscrit au cœur de cette problématique. En fait, nous avons pu développer une procédure complète pour la détection et l'isolation de défauts basée sur les modèles flous et l'appliquer avec succès à un échangeur de chaleur pilote. La démarche n'était guère aisée car il a fallu donner une justification pratique à l'approche théorique en commençant tout d'abord par répondre à l'une des principales interrogations que nous nous sommes posées et qui concerne la capacité de l'approximation d'un modèle flou, notamment pour le cas de l'échangeur de chaleur qui fait bien partie de la classe des systèmes à paramètres distribués. Autrement dit, un modèle flou peut-il uniformément reproduire le comportement dynamique de n'importe quel processus sur un sous-ensemble compact avec un degré de précision arbitraire ? Ensuite, il a fallu valider l'algorithme de surveillance basé sur la manipulation de ces modèles flous. La réponse par l'affirmatif allait apporter une justification de plus aux succès de la logique floue rencontrés au niveau des applications, et c'était bien le cas comme le montrent clairement les résultats expérimentaux obtenus.

Pour parvenir à réaliser cette tâche, nous avons considéré les niveaux d'étude intermédiaires suivants :

- Présenter la structure générale d'un système de surveillance à base de modèles et donner quelques notions et outils de base.

- Faire un rappel de certaines stratégies de génération de résidus se basant sur l'utilisation des modèles mathématiques.
- Exposer les bases méthodologiques de la méthode d'identification des modèles flous TS et leur utilisation pour la conception d'algorithmes de surveillance.
- Appliquer l'approche floue à un échangeur de chaleur pilote.

Pour la mise en œuvre du système de surveillance, plusieurs essais ont été réalisés. Des modèles flous ont été identifiés à partir des mesures entrées-sorties et validés en ligne. Ces modèles ont été ensuite utilisés pour la construction des prédicteurs flous desquels est composé le système de détection et d'isolation des défauts considérés. L'évaluation des résidus générés est effectuée à l'aide de l'algorithme récurrent CUSUM. Dans toute cette démarche, un intérêt particulier a été réservé au problème de fuite d'eau dans l'échangeur de chaleur. Ce problème étant assez fréquent en milieu industriel, d'autant plus qu'il se manifeste de manière graduelle et provoque donc des dégradations lentes.

Les résultats obtenus pour l'ensemble des cas envisagés sont très satisfaisants et peuvent être améliorés davantage. En effet, l'approche développée dans cette thèse peut être élargie à l'étude des défauts multiples qui n'ont pas été envisagés dans les essais. Pour ce faire, d'autres prédicteurs flous peuvent être identifiés et rajoutés au générateur de résidus que nous avons établi. Aussi, il est possible de réduire la structure des modèles flous TS identifiés à l'aide de mécanismes appropriés (voir Annexe C). Cette démarche n'étant pas considérée dans nos essais car l'effort de calcul que nécessite l'algorithme de surveillance implémenté avec les modèles flous non réduits n'était pas aussi important devant la dynamique relativement lente de l'échangeur de chaleur. Cependant, elle peut s'avérer utile dans le cas où l'on envisage d'étudier les défauts multiples.

Les perspectives demeurent nombreuses et doivent être orientées vers les aspects suivants :

- En ce qui concerne l'échangeur de chaleur proprement dit, il est important d'envisager d'autres modes de fonctionnement afin de cerner au mieux la réalité physique du processus, typiquement le mode qui fait intervenir la variation du débit d'eau. Bien que la variation du débit d'eau est souvent introduite de manière graduelle et lente en pratique, son influence en tant que source significative de non linéarités ne doit pas être négligée.
- Concernant l'identification, la mise en œuvre d'une méthode d'identification de modèles flous TS en temps réel peut s'avérer intéressante dans la mesure où elle permettrait de caractériser au mieux la dynamique non linéaire de l'échangeur de chaleur ainsi que le mode courant de son fonctionnement.
- Pour la surveillance, plusieurs pistes sont à poursuivre :
 - des algorithmes de surveillance basés sur des modèles flous TS identifiés en ligne (auto-organisation de la base des règles floues) ;

- des algorithmes de surveillance basés sur des observateurs flous (le problème de stabilité des observateurs flous est toujours ouvert) ;
- la surveillance à l'aide d'observateurs adaptatifs ;
- caractérisation des défauts par des modèles flous : le diagnostic devient alors un problème de reconnaissance de formes ou de classification dans des formes acquises (un problème qui dépend essentiellement de la disponibilité d'une base de connaissances suffisante sur les défauts considérés).

Annexe A

Paramètres physiques de l'échangeur de chaleur

A.1. Echange thermique

Paramètre	Désignation	Ordre de grandeur
Chaleur spécifique du cuivre	c_m	850 Kcal/m ³ °K
Chaleur spécifique de l'air	c_a	0,24 Kcal/m ³ °K
Chaleur spécifique de l'eau	c_e	1000 Kcal/m ³ °K
Section interne des tubes	S_{int}	3 mm
Section externe des tubes	S_{ext}	5 mm
Longueur totale des tubes	L	7,5 m
Longueur de l'échangeur de chaleur	l	0.33 m
Nombre de nappes	–	5
Nombre de tubes par nappe	–	24
Section de passage de l'air	S_a	1,82.10 ⁻² m ²
Section de passage de l'eau	S_e	3,53.10 ⁻⁵ m ²
Section du métal	S_m	6,28.10 ⁻⁵ m ²
Périmètre d'échange pour l'air	D_a	0.0785 m ²
Périmètre d'échange pour l'eau	D_e	0.0471 m ²
Chute de pression de l'air	Δp	0 < Δp < 200 Kg/m ²
Débit de l'air	Q_a	0 < Q_a < 1,29 m ³ /s
Débit de l'eau	Q_e	0 < Q_e < 2,78.10 ⁻⁵ m ³ /s
Vitesse de l'air	v_a	0 < v_a < 70,9 m/s
Vitesse de l'eau	v_e	0 < v_e < 0,788 m/s
Temps de parcours de l'air	t_a	$t_a > 4,65.10^{-3}$ s
Temps de parcours de l'eau	t_e	$t_e > 9,52$ s
Coefficient d'échange métal-air	α_{ma}	2,10 ⁻² Kcal/m ² s °K
Constante de temps air-air	τ_a	2,78 s
Constante de temps eau-air	τ_e	22,48 s
Constante de temps métal-air	τ_m	34 s
Facteur d'échelle	l_a	0,044

A.2. Chauffage et conduite d'air

Paramètre	Désignation	Ordre de grandeur
Section interne de la conduite	S_{int}	0,143 m
Section de passage de l'air	S_a	$1,6 \cdot 10^{-2} \text{ m}^2$
Section du métal	S_m	$5 \cdot 10^{-4} \text{ m}^2$
Périmètre d'échange	D_a	0,449 m
Vitesse de l'air	v_a	$0 < v_a < 80,6 \text{ m/s}$
Constante de temps air-air	τ_a	0,428 s
Constante de temps métal-air	τ_m	47,3 s
Gain statique du dispositif de chauffe	k_c	$k_c > 1^\circ\text{K/KW}$
Constante de temps du dispositif de chauffe	τ_c	$\tau_c > 1,40 \text{ s}$

Annexe B

Algorithme de somme cumulée (CUSUM)

- **Etant donnés :**

1. Un ensemble de données expérimentales $\{z(1), \dots, z(N)\}$ obtenues en mode de fonctionnement sain.
2. Une estimation de l'amplitude du changement à détecter.
3. Le délai moyen de détection ou le temps moyen entre les fausses alarmes souhaités.

- **Initialisation :**

1. Déterminer $\hat{\mathbf{v}}_0$ et $\hat{\mathbf{\Sigma}}$ à partir de $\{z(1), \dots, z(N)\}$.
2. Choisir un seuil de décision h conformément au délai de détection ou bien au temps moyen entre les fausses alarmes souhaités.

- **A chaque instant k :**

1. Acquérir un nouveau vecteur de données $\mathbf{z}(k)$.
2. Calculer la fonction de décision $g(k)$.
3. Evaluer les règles de détection, générer une alarme si l'hypothèse des défauts est retenue puis réinitialiser la fonction de décision.

- **Résultat :** Une séquence d'alarmes générées aux instants k_a et une estimation des instants d'occurrence des défauts \hat{k}_0 sur un horizon de temps croissant.

Annexe C

Sur la simplification des modèles flous TS

Dans une procédure d'identification de modèles flous se basant sur la technique du clustering, il est nécessaire de préciser le nombre de groupes de données (clusters) que doit identifier l'algorithme utilisé. Dans le cas où l'on ne dispose pas de connaissances suffisantes sur la structure générale des données manipulées, on est souvent contraint d'admettre un nombre surestimé c de clusters qu'il soit réellement représentatif ou non de la structure de données recherchée. Ensuite, une des principales approches suivantes peut être employée pour déterminer le nombre optimal de clusters [SIM 02] :

1. Appliquer l'algorithme aux données disponibles pour différentes valeurs de c , et faire appel, ensuite, à des mesures de validité appropriées [TSE 05; EMA 98] pour évaluer la performance des partitions obtenues.
2. Considérer un nombre suffisamment grand de clusters, que l'on réduit successivement par la fusion des clusters similaires (compatibles) en se basant sur un critère de similitude (compatibilité) prédéfini.

Dans la suite, nous exposons sommairement la deuxième approche, avant de l'appliquer au modèle flou identifié pour l'échangeur de chaleur dans le chapitre 4.

C.1. Fusion des clusters compatibles

La méthode de fusion des clusters compatibles (CCM) a été initialement proposée dans [KRI 92]. Partant du fait que les clusters identifiés sont assimilables à des hyperplans (en réalité ce sont des hyper-ellipsoïdes), un certain nombre de conditions est posé pour détecter et fusionner, voire éliminer, les clusters compatibles. La démarche est essentiellement basée sur l'analyse des valeurs propres et des vecteurs propres des matrices de covariance de tous les clusters considérés.

Pour ce faire, considérons deux clusters de centres \mathbf{v}_i et \mathbf{v}_j , caractérisés par les matrices de covariance \mathbf{F}_i et \mathbf{F}_j . Désignons respectivement par η_i et ϑ_i la petite valeur propre et le vecteur propre associé de la matrice de covariance du cluster i . Ainsi, les critères suivants sont définis pour fusionner les deux clusters [KRI 92; ZHA 94]:

$$|\vartheta_i \cdot \vartheta_j| \geq C_1 \quad (\text{C.1})$$

$$\left| \frac{\vartheta_i + \vartheta_j}{2} \cdot \frac{\mathbf{v}_i - \mathbf{v}_j}{\|\mathbf{v}_i - \mathbf{v}_j\|} \right| \leq C_2 \quad (\text{C.2})$$

$$\|\mathbf{v}_i - \mathbf{v}_j\| \leq C_3 (\sqrt{\eta_i} + \sqrt{\eta_j}) \quad (\text{C.3})$$

où C_1 , C_2 et C_3 représentent des seuils à choisir. D'après [KRI 92], il convient d'opter pour les valeurs suivantes : C_1 proche de 1, C_2 proche de 0 et $C_3 \in [2, 4]$.

La condition (C.1) signifie que les hyperplans représentés par les deux clusters i et j doivent être approximativement parallèles. La condition (C.2) traduit le fait que les normales à ces deux hyperplans doivent être approximativement perpendiculaires à la ligne droite reliant les deux centres \mathbf{v}_i et \mathbf{v}_j , alors que la condition (C.3) signifie que les clusters doivent être étroitement proches. Les trois conditions réunies conduisent à la fusion des clusters i et j en un seul, donc à la simplification de la structure des règles IF-THEN du modèle flou.

C.2. Application de l'algorithme CCM au modèle flou TS (\mathcal{M}) de l'échangeur de chaleur

Rappelons que le modèle flou TS (\mathcal{M}) décrit la variation de la température d'eau T_{34} en fonction de la température d'air T_{16} , de la puissance de chauffe P_c et de la position de la vanne de recyclage d'air V_a , c'est-à-dire :

$$(\mathcal{M}) : T_{34}(k+1) = f(T_{34}(k), T_{16}(k), P_c(k), V_a(k)) \quad (\text{C.4})$$

Le modèle flou TS résultant de l'algorithme de clustering de Gustafson-Kessel est composé de trois règles IF-THEN dont la i ème règle est de la forme :




Figure C.1 : Fonctions d'appartenance du modèle flou TS (\mathcal{M}) réduit.

$$\begin{aligned}
 (\mathcal{M}) : \quad & \text{If } P_c(k) \text{ is } A_{11}^i \text{ and } V_a(k) \text{ is } A_{12}^i \text{ and } T_{16}(k) \text{ is } A_{13}^i \text{ and } T_{34}(k) \text{ is } A_{14}^i \\
 & \text{Then } T_{34}(k+1) = b_1^i + a_{11}^i P_c(k) + a_{12}^i V_a(k) + a_{13}^i T_{16}(k) + a_{14}^i T_{34}(k)
 \end{aligned} \tag{C.5}$$

Si l'on admet pour chaque variable linguistique trois valeurs qualitatives *i.e.* $A_{1j} = \{PS, PM, PB\}$, $j = 1, \dots, 4$, le modèle non réduit (C.5) est intégralement défini par l'ensemble des règles suivantes :

$$\begin{aligned}
 & \text{If } P_c(k) \text{ is } PS \text{ and } V_a(k) \text{ is } PS \text{ and } T_{16}(k) \text{ is } PS \text{ and } T_{34}(k) \text{ is } PS \\
 & \quad \text{Then } T_{34}(k+1) = b_1^1 + a_{11}^1 P_c(k) + a_{12}^1 V_a(k) + a_{13}^1 T_{16}(k) + a_{14}^1 T_{34}(k) \\
 & \text{and} \\
 & \text{If } P_c(k) \text{ is } PM \text{ and } V_a(k) \text{ is } PB \text{ and } T_{16}(k) \text{ is } PM \text{ and } T_{34}(k) \text{ is } PM \\
 & \quad \text{Then } T_{34}(k+1) = b_1^2 + a_{11}^2 P_c(k) + a_{12}^2 V_a(k) + a_{13}^2 T_{16}(k) + a_{14}^2 T_{34}(k)
 \end{aligned} \tag{C.6}$$

If $P_c(k)$ is *PB* and $V_a(k)$ is *PM* and $T_{16}(k)$ is *PB* and $T_{34}(k)$ is *PB*

$$\text{Then } T_{34}(k+1) = b_1^3 + a_{11}^3 P_c(k) + a_{12}^3 V_a(k) + a_{13}^3 T_{16}(k) + a_{14}^3 T_{34}(k)$$

Les coefficients a_{1j}^i et b_1^i , $i = 1, \dots, 3$, $j = 1, \dots, 4$, des modèles locaux ARX figurant dans les conditions des règles floues sont indiqués dans le tableau 4.1.

Pour réduire la structure du modèle flou TS (C.6), nous avons appliqué l'algorithme de fusion des clusters compatibles (CCM) décrit dans la section C.1. Les partitions floues résultantes sont données en figure (C.1). Cela revient à reformuler la base des règles du modèle flou (\mathcal{M}) sous la forme suivante :

If $P_c(k)$ is *PS* and $V_a(k)$ is *PB* and $T_{16}(k)$ is *PS* and $T_{34}(k)$ is *PS*

$$\text{Then } T_{34}(k+1) = b_1^1 + a_{11}^1 P_c(k) + a_{12}^1 V_a(k) + a_{13}^1 T_{16}(k) + a_{14}^1 T_{34}(k)$$

and

If $P_c(k)$ is *PB* and $T_{16}(k)$ is *PM* and $T_{34}(k)$ is *PM*

$$\text{Then } T_{34}(k+1) = b_1^2 + a_{11}^2 P_c(k) + a_{12}^2 V_a(k) + a_{13}^2 T_{16}(k) + a_{14}^2 T_{34}(k) \quad (\text{C.7})$$

and

If $T_{16}(k)$ is *PB* and $T_{34}(k)$ is *PB*

$$\text{Then } T_{34}(k+1) = b_1^3 + a_{11}^3 P_c(k) + a_{12}^3 V_a(k) + a_{13}^3 T_{16}(k) + a_{14}^3 T_{34}(k)$$

Remarquons que dans la structure simplifiée (C.7), les valeurs qualitatives de la variable de décision P_c se sont réduites à deux, celles de la variable V_a sont réduites à une seule valeur. La démarche est intéressante mais pourrait faire nuire à la capacité d'approximation universelle du modèle flou réduit (voir [FIN 00]).

Annexe C

Sur la simplification des modèles flous TS

Dans une procédure d'identification de modèles flous se basant sur la technique du clustering, il est nécessaire de préciser le nombre de groupes de données (clusters) que doit identifier l'algorithme utilisé. Dans le cas où l'on ne dispose pas de connaissances suffisantes sur la structure générale des données manipulées, on est souvent contraint d'admettre un nombre surestimé c de clusters qu'il soit réellement représentatif ou non de la structure de données recherchée. Ensuite, une des principales approches suivantes peut être employée pour déterminer le nombre optimal de clusters [SIM 02] :

1. Appliquer l'algorithme aux données disponibles pour différentes valeurs de c , et faire appel, ensuite, à des mesures de validité appropriées [TSE 05; EMA 98] pour évaluer la performance des partitions obtenues.
2. Considérer un nombre suffisamment grand de clusters, que l'on réduit successivement par la fusion des clusters similaires (compatibles) en se basant sur un critère de similitude (compatibilité) prédéfini.

Dans la suite, nous exposons sommairement la deuxième approche, avant de l'appliquer au modèle flou identifié pour l'échangeur de chaleur dans le chapitre 4.

C.1. Fusion des clusters compatibles

La méthode de fusion des clusters compatibles (CCM) a été initialement proposée dans [KRI 92]. Partant du fait que les clusters identifiés sont assimilables à des hyperplans (en réalité ce sont des hyper-ellipsoïdes), un certain nombre de conditions est posé pour détecter et fusionner, voire éliminer, les clusters compatibles. La démarche est essentiellement basée sur l'analyse des valeurs propres et des vecteurs propres des matrices de covariance de tous les clusters considérés.

Pour ce faire, considérons deux clusters de centres \mathbf{v}_i et \mathbf{v}_j , caractérisés par les matrices de covariance \mathbf{F}_i et \mathbf{F}_j . Désignons respectivement par η_i et ϑ_i la petite valeur propre et le vecteur propre associé de la matrice de covariance du cluster i . Ainsi, les critères suivants sont définis pour fusionner les deux clusters [KRI 92; ZHA 94]:

$$|\vartheta_i \cdot \vartheta_j| \geq C_1 \quad (\text{C.1})$$

$$\left| \frac{\vartheta_i + \vartheta_j}{2} \cdot \frac{\mathbf{v}_i - \mathbf{v}_j}{\|\mathbf{v}_i - \mathbf{v}_j\|} \right| \leq C_2 \quad (\text{C.2})$$

$$\|\mathbf{v}_i - \mathbf{v}_j\| \leq C_3 (\sqrt{\eta_i} + \sqrt{\eta_j}) \quad (\text{C.3})$$

où C_1 , C_2 et C_3 représentent des seuils à choisir. D'après [KRI 92], il convient d'opter pour les valeurs suivantes : C_1 proche de 1, C_2 proche de 0 et $C_3 \in [2, 4]$.

La condition (C.1) signifie que les hyperplans représentés par les deux clusters i et j doivent être approximativement parallèles. La condition (C.2) traduit le fait que les normales à ces deux hyperplans doivent être approximativement perpendiculaires à la ligne droite reliant les deux centres \mathbf{v}_i et \mathbf{v}_j , alors que la condition (C.3) signifie que les clusters doivent être étroitement proches. Les trois conditions réunies conduisent à la fusion des clusters i et j en un seul, donc à la simplification de la structure des règles IF-THEN du modèle flou.

C.2. Application de l'algorithme CCM au modèle flou TS (\mathcal{M}) de l'échangeur de chaleur

Rappelons que le modèle flou TS (\mathcal{M}) décrit la variation de la température d'eau T_{34} en fonction de la température d'air T_{16} , de la puissance de chauffe P_c et de la position de la vanne de recyclage d'air V_a , c'est-à-dire :

$$(\mathcal{M}) : T_{34}(k+1) = f(T_{34}(k), T_{16}(k), P_c(k), V_a(k)) \quad (\text{C.4})$$

Le modèle flou TS résultant de l'algorithme de clustering de Gustafson-Kessel est composé de trois règles IF-THEN dont la i ème règle est de la forme :




Figure C.1 : Fonctions d'appartenance du modèle flou TS (\mathcal{M}) réduit.

$$\begin{aligned}
 (\mathcal{M}) : \quad & \text{If } P_c(k) \text{ is } A_{11}^i \text{ and } V_a(k) \text{ is } A_{12}^i \text{ and } T_{16}(k) \text{ is } A_{13}^i \text{ and } T_{34}(k) \text{ is } A_{14}^i \\
 & \text{Then } T_{34}(k+1) = b_1^i + a_{11}^i P_c(k) + a_{12}^i V_a(k) + a_{13}^i T_{16}(k) + a_{14}^i T_{34}(k)
 \end{aligned} \tag{C.5}$$

Si l'on admet pour chaque variable linguistique trois valeurs qualitatives *i.e.* $A_{1j} = \{PS, PM, PB\}$, $j = 1, \dots, 4$, le modèle non réduit (C.5) est intégralement défini par l'ensemble des règles suivantes :

$$\begin{aligned}
 & \text{If } P_c(k) \text{ is } PS \text{ and } V_a(k) \text{ is } PS \text{ and } T_{16}(k) \text{ is } PS \text{ and } T_{34}(k) \text{ is } PS \\
 & \quad \text{Then } T_{34}(k+1) = b_1^1 + a_{11}^1 P_c(k) + a_{12}^1 V_a(k) + a_{13}^1 T_{16}(k) + a_{14}^1 T_{34}(k) \\
 & \text{and} \\
 & \text{If } P_c(k) \text{ is } PM \text{ and } V_a(k) \text{ is } PB \text{ and } T_{16}(k) \text{ is } PM \text{ and } T_{34}(k) \text{ is } PM \\
 & \quad \text{Then } T_{34}(k+1) = b_1^2 + a_{11}^2 P_c(k) + a_{12}^2 V_a(k) + a_{13}^2 T_{16}(k) + a_{14}^2 T_{34}(k)
 \end{aligned} \tag{C.6}$$

If $P_c(k)$ is *PB* and $V_a(k)$ is *PM* and $T_{16}(k)$ is *PB* and $T_{34}(k)$ is *PB*

$$\text{Then } T_{34}(k+1) = b_1^3 + a_{11}^3 P_c(k) + a_{12}^3 V_a(k) + a_{13}^3 T_{16}(k) + a_{14}^3 T_{34}(k)$$

Les coefficients a_{1j}^i et b_1^i , $i = 1, \dots, 3$, $j = 1, \dots, 4$, des modèles locaux ARX figurant dans les conditions des règles floues sont indiqués dans le tableau 4.1.

Pour réduire la structure du modèle flou TS (C.6), nous avons appliqué l'algorithme de fusion des clusters compatibles (CCM) décrit dans la section C.1. Les partitions floues résultantes sont données en figure (C.1). Cela revient à reformuler la base des règles du modèle flou (\mathcal{M}) sous la forme suivante :

If $P_c(k)$ is *PS* and $V_a(k)$ is *PB* and $T_{16}(k)$ is *PS* and $T_{34}(k)$ is *PS*

$$\text{Then } T_{34}(k+1) = b_1^1 + a_{11}^1 P_c(k) + a_{12}^1 V_a(k) + a_{13}^1 T_{16}(k) + a_{14}^1 T_{34}(k)$$

and

If $P_c(k)$ is *PB* and $T_{16}(k)$ is *PM* and $T_{34}(k)$ is *PM*

$$\text{Then } T_{34}(k+1) = b_1^2 + a_{11}^2 P_c(k) + a_{12}^2 V_a(k) + a_{13}^2 T_{16}(k) + a_{14}^2 T_{34}(k) \quad (\text{C.7})$$

and

If $T_{16}(k)$ is *PB* and $T_{34}(k)$ is *PB*

$$\text{Then } T_{34}(k+1) = b_1^3 + a_{11}^3 P_c(k) + a_{12}^3 V_a(k) + a_{13}^3 T_{16}(k) + a_{14}^3 T_{34}(k)$$

Remarquons que dans la structure simplifiée (C.7), les valeurs qualitatives de la variable de décision P_c se sont réduites à deux, celles de la variable V_a sont réduites à une seule valeur. La démarche est intéressante mais pourrait faire nuire à la capacité d'approximation universelle du modèle flou réduit (voir [FIN 00]).

Bibliographie

- [ABO 01] Abonyi J., R. Babuska et F. Szeifert. (2001). Modified Gath-Geva clustering for identification of Takagi-Sugeno fuzzy models. Depuis le site *internet* <http://www.fmt.vein.hu/softcomp>.
- [ALC 96] Alcorta-Garcia E. et P. M. Frank. (1996). Analysis of a class of dedicated observer schemes to sensor fault isolation. *Proceedings UKACC International conference on control*, pp. 60-65.
- [ALC 98] Alcorta-Garcia E., R. Seliger et P. M. Frank. (1998). Nonlinear decoupling approach to fault isolation in linear systems. *Proceedings of the ACC, USA*, pp. 2867-2871.
- [ALC 03] Alcorta-Garcia E. et S. S. Flores. (2003). Fault detection and isolation based on Takagi-Sugeno modelling. *Proceedings of IEEE International symposium on intelligent control, Texas*, pp. 673-678.
- [ALE 04] Alexiev K.M. et O.I. Georgieva. (2004). Improved fuzzy clustering for identification of Takagi-Sugeno model. *Proceedings of second IEEE international conference on intelligent systems*, pp. 213-218.
- [ANG 04] Angelov P.P. et D.P. Filev. (2004). An approach to online identification of Takagi-Sugeno fuzzy models. *IEEE Trans. on systems, man and cybernetics*, vol.34, n°1, pp. 484-498.
- [AYO 95] Ayoubi M. (1995). Neuro-fuzzy structure for rule generation and application in the fault diagnosis of technical processes. *Proceedings of the ACC, USA*, pp. 2757-2761.
- [BAL 97] Ballé P., D. Juricic, A. Rakar et S. Ernst (1997). Identification of nonlinear processes and model based fault isolation using local linear models. *Proceedings of the ACC, New Mexico*, pp. 47-51.
- [BAL 99] Ballé P. (1999). Fuzzy-model-based parity equations for fault isolation. *Control Engineering Practice*, vol. 7, pp. 261-270.
- [BAL 00] Ballé P. et D. Fuessel. (2000). Closed-loop fault diagnosis based on a nonlinear process model and automatic fuzzy rule generation. *Engineering application of artificial intelligence*, vol. 13, pp. 695-704.
- [BAS 93] Basseville M. et I.V. Nikiforov. (1993). *Detection of abrupt changes – Theory and applications*. Information and system sciences series. Prentice Hall, Englewood Cliffs, N.J.
- [BEA 71] Beard R.V. (1971). *Failure accommodation in linear system through self-reorganization*. Thèse de Doctorat, MIT.
- [BEN 96] Benkhedda H. et R. Patton. (1996). Fault diagnosis using quantitative and qualitative knowledge integration. *Proceedings UKACC International conference on control*, pp. 849-854.

- [BLA 03] Blank M., M. Kinnaert, J. Lunze et M. Staroswiecki. (2003). *Diagnosis and fault tolerant control*. Springer Editions.
- [BOC 06] Bocaniala C.D. et J.S. da Costa. (2006). Application of a novel fuzzy classifier to fault detection and isolation of the DAMADICS benchmark problem. *Control engineering practice*, Vol. 14, pp. 653-669.
- [BOG 98] Bogaerts Ph., A. Cuvelier et M. Kinnaert. (1998). Identification for fault detection in an industrial condenser. *Control engineering practice*, vol.6, pp. 1249-1256.
- [BRU 96] de Bruin H.A.E. et B. Roffel. (1996). A new identification method for fuzzy linear models of nonlinear dynamic systems. *Journal of process control*, vol.6, n°.5, pp. 277-293.
- [CAO 97a] Cao S., N. W. Rees et G. Feng. (1997). Analysis and design for a class of complex control systems – Part I: Fuzzy modelling and identification, *Automatica*, 33(6), pp. 1017-1028.
- [CAO 97b] Cao S., N. W. Rees et G. Feng. (1997). Analysis and design for a class of complex control systems – Part II: Fuzzy controller design, *Automatica*, 33(6), pp. 1029-1039.
- [CHA 02] Chadli M. (2002). *Stabilité et commande de systèmes décrits par des multimodèles*. Thèse de Doctorat de l’Institut National Polytechnique de Lorraine, France.
- [CHO 84] Chow E.Y. et A.S. Willsky. (1984). Analytical redundancy and the design of robust detection systems. *IEEE Trans. on automatic control*, vol. 29, n°. 7.
- [CLA 78] Clark R.N. (1978). Instrument fault detection. *IEEE Trans. on aerospace and electronic systems*, vol. 14.
- [DEX 97] Dexter A.L. et M. Benouarets. (1997). Model-based fault diagnosis using fuzzy matching. *IEEE Trans. on systems, man and cybernetics*, vol.27, n°.5, pp. 673-682.
- [DID 03] Didier M. (2003). *Surveillance de Processus*. Polycopie de l’Institut National Polytechnique de Lorraine, France.
- [DIN 91] Ding X. et P. M. Frank (1991). Frequency domain approach and threshold selector for robust model-based fault detection and isolation. *Proceeding of the IFAC symposium SAFEPROCESS’91*, vol. 1, pp. 307-312.
- [DRI 96] Driankov D., H. Hellendoorn et M. Reinfrank. (1996). *An introduction to fuzzy control*. Springer-Verlag Editions.
- [EMA 98] Emami M.R., B. Türksen et A.A. Goldenberg. (1998). Development of a systematic methodology of fuzzy logic modeling. *IEEE Trans. on fuzzy systems*, vol.6., n°.3, pp. 346-361.
- [FIN 00] Fink A., M. Fischer, O. Nelles et R. Isermann. (2000). Supervision of nonlinear adaptive controllers based on fuzzy models. *Control Engineering Practice*, vol. 8, pp. 1093-1105.
- [FRA 97a] Frank P.M. and X. Ding. (1997). Survey of robust residual generation and evaluation methods in observer-based fault detection systems. *Journal of process control*, Vol. 7, N°. 6, pp. 403-424.
- [FRA 97b] Frank P.M. et N. Kiupel. (1997). FDI with computer-assisted human intelligence. *Proceedings of the ACC, New Mexico*, pp. 913-917.
- [FRA 97c] Frank P.M. et B. Köppen-Seliger. (1997). Fuzzy logic and neural network applications to fault diagnosis. *International journal of approximate reasoning*, vol.16, pp. 67-88.

- [FRA 00] Frank P.M., E. Alcorta and B. Köppen-Seliger. (2000). Modelling for fault detection and isolation versus modelling for control. *Mathematics and computers in simulation*, vol. 53, pp. 259-271.
- [GAR 00] Garcia F.J., V. Izquierdo, L.J. de Miguel et J.R. Peran. (2000). Fault diagnostic system using analytical fuzzy redundancy. *Engineering applications of artificial intelligence*, vol. 13, pp. 441-450.
- [GER 88] Gertler J. J. (1988). Survey of model-based failure detection and isolation in complex plants. *IEEE Control system magazine*, pp. 3-11.
- [GER 91] Gertler J. J. (1991). Analytical redundancy methods in fault detection and isolation. *Proceedings of the IFAC SAFEPROCESS symposium'91*.
- [GER 95] Gertler J. J. (1995). Diagnosing parametric faults: from parameter estimation to parity relations. *Proceedings of the ACC, USA*, pp. 1615-1620.
- [GOM 99] Gomez-Skarmeta A.F., M. Delgado et M.A. Vila. (1999). About the use of fuzzy clustering techniques for fuzzy model identification. *Fuzzy sets and systems*, vol.106, pp. 179-188.
- [GUS 79] Gustafson D. E. et W. C. Kessel. (1979). Fuzzy clustering with a fuzzy covariance matrix, *Proceeding IEEE CDC, San Diego, CA*, pp.761-766.
- [HAB 03] Habbi H., Zelmat M. et Ould Bouamama B. (2003). A dynamic fuzzy model for a drum boiler-turbine system. *Automatica*, Vol. 39, Issue 7, pp. 1213-1219.
- [HEY 97] Heywood M. I. et C. R. Chatwin. (1997). Neuro-fuzzy approaches to fault diagnosis and identification. *Institution of Electrical Engineers, published by IEE, UK*.
- [HIM 78] Himmelblau D.M. (1978). Fault detection and diagnosis in chemical and petrochemical processes. Elsevier, Amsterdam.
- [ICH 01] Ichtev A., J. Hellendoorn et R. Babuska. (2001). Fault detection and isolation using multiple Takagi-Sugeno fuzzy models. *Proceedings of the IEEE International fuzzy systems conference*, pp. 1498-1502.
- [ISE 84] Isermann R. (1984). Process fault diagnosis based on modeling and estimation methods – A survey. *Automatica*, vol. 20, pp. 387-404.
- [ISE 94] Isermann R. (1994). Integration of fault detection and diagnosis methods. *Proceeding of the IFAC SAFEPROCESS Symposium'94*.
- [ISE 97] Isermann R. (1997). Supervision, fault detection and fault diagnosis methods – An introduction. *Control engineering practice*, Vol. 5, N°. 5, pp. 639-652.
- [ISE 98] Isermann R. (1998). On fuzzy logic applications for automatic control, supervision and fault diagnosis, *IEEE Transactions on systems, man and cybernetics – Part A*, vol. 28, n°. 2, pp.221-235.
- [JAM 93] Jamshidi M., N. Vadiie et T.J. Ross. (1993). *Fuzzy logic and control : Software and hardware applications*. Prentice Hall, New Jersey.
- [JAN 95] Jang J.S. C.T. Sun. (1995). Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, vol.83,n°.3, pp. 378-405.
- [JOH 00] Johansen T.A., R. Shorten et R. Murray-Smith. (2000). On the interpretation and identification of dynamic Takagi-Sugeno fuzzy models. *IEEE Trans. on fuzzy systems*, vol.8, n°.3, pp.297-313.

- [KIN 00] Kinnaert M., D. Vrancic, E. Denolin, D. Juricic et J. Petrovcic. (2000). Model-based fault detection and isolation for a gas-liquid separation unit. *Control Engineering Practice*, vol. 8, pp. 1273-1283.
- [KRI 92] Krishnapuram R. et C. Freg. (1992). Fitting an unknown number of lines and planes to image data through compatible cluster merging. *Pattern recognition*, vol. 25, n°. 4, pp. 385-340.
- [LAU 94] Laukonen E.G. et K.M. Passino. (1994). Fuzzy systems for function approximation with application to failure estimation. *IEEE International symposium on intelligent control*, Ohio, USA, pp. 184-189.
- [LEE 99] Lee J., S. Bae, K. Lee et G. Park (1999). Fault diagnosis of nonlinear system based on fuzzy dynamic model. *Proceedings of the IEEE International conference on fuzzy systems, Korea*, pp. 245-250.
- [LEO 97] Leonhardt S. et M. Ayoubi. (1997). Methods of fault diagnosis. *Control engineering practice*, vol.5, pp. 683-692.
- [LV 04] Lv N., X. Yu et J. Wu. (2004). A fault diagnosis model through GK fuzzy clustering. *Proceeding of IEEE International conference on systems, man and cybernetics*, pp. 5114-5118.
- [LUY 86] Luyben W.L. (1986). *Process modeling, simulation and control for chemical engineers*. McGraw-Hill Editions.
- [MAS 86] Massoumnia M. (1986). A geometric approach to the synthesis of failure detection filters. *IEEE Trans. on automatic control*, AC(31), pp. 839-846.
- [NAE 88] Emami-Naeini A.E., M.M. Akhter et S.M. Rock. (1988). Effect of model uncertainty on failure detection: the threshold selector. *IEEE trans. on automatic control*, vol. AC-33, n°.2, pp. 1106-1115.
- [PAN 04] Panchariya P.C., A.K. Palit et D. Popovic. (2004). Nonlinear system identification using Takagi-Sugeno type neuro-fuzzy model. *Second IEEE International conference on intelligent systems*, pp. 76-81.
- [PAN 05] Panella M., et A.S. Gallo. (2005). An input-output clustering approach to the synthesis of ANFIS networks. *IEEE Trans. on fuzzy systems*, vol.13, n°.1, pp. 69-81.
- [PAT 99] Patton R.J. (1999). Preface to the papers from the 3rd IFAC Symposium SAFEPROCESS'97. *Control engineering practice*, vol. 7, n°. 1, pp. 201-202.
- [PAT 01] Patton R.J., L. Toribio et S. Simani. (2001). Robust fault diagnosis in a chemical process using multiple-model approach. *Proceedings of the 40th IEEE CDC, Orlando, USA*, pp. 149-154.
- [PED 93] Pedrycz W. (1993). *Fuzzy control and fuzzy systems*. Research studies press ltd., England.
- [PEN 97] Peng Y., A. Youssouf, P. Arte et M. Kinnaert. (1997). A complete procedure for residual generation and evaluation with application to a heat exchanger. *IEEE Trans. on control systems technology*, vol. 5, n°. 6, pp. 542-555.
- [PER 05] Persin S. et B. Tovornik. (2005). Real-time implementation of fault diagnosis to a heat exchanger. *Control engineering practice*, vol.13, pp. 1061-1069.
- [REN 95] Renders J-M. (1995). Algorithmes génétiques et réseaux de neurones: application à la commande de processus. Editions Hermès, France.

- [SEL 91] Seliger R. et P. M. Frank. (1991). Fault diagnosis by disturbance decoupled nonlinear observers. *Proceedings of the 30th CDC, England*, pp. 2248-2253.
- [SET 00] Setnes M. (2000). Supervised fuzzy clustering for rule extraction. *IEEE Trans. on fuzzy systems*, vol.8, n°.4, pp. 416-424.
- [SIL 86] Silverman B. (1986). *Density estimation for statistics and data analysis*. Chapman and Hall, London.
- [SIM 99] Simani S. (1999). *Model-based fault diagnosis in dynamic systems using identification techniques*. Thèse de Doctorat de l'Université de Ferrara, Italie.
- [SIM 02] Simani S., C. Fantuzzi et R.J. Patton (2002). *Model-based fault diagnosis in dynamic systems using identification techniques*. Springer-Verlag Editions.
- [SKR 00] Skrjanc I. et D. Matko. (2000). Predictive functional control based on fuzzy model for heat exchanger pilot plant. *IEEE Trans. On Fuzzy systems*, vol. 8, N°. 6, pp. 705-712.
- [SPR 00] Spreitzer K. et P. Ballé. (2000). A multi-model approach for detection and isolation of sensor and process faults for a heat exchanger. *Proceedings of the ACC, USA*, pp. 2730-2734.
- [STA 00] Staroswiecki M. (2000). Quantitative and qualitative models for fault detection and isolation. *Mechanical systems and signal processing*, vol. 14(3), pp. 301-325.
- [STO 82] Stone C. (1982). Optimal global rates of convergence for nonparametric regression. *The annals of statistics*, vol. 10, pp. 1040-1053.
- [SUG 88] Sugeno M. et G. T. Kang. (1988). Structure identification of fuzzy model. *Fuzzy set and systems*, n°. 28, pp.15-13.
- [SZE 98] Szederkenyi G. (1998). *Model-based fault detection of heat exchangers*. Thèse de l'Université de Veszprém, Hongrie.
- [TAK 85] Takagi M. et M. Sugeno. (1985). Fuzzy identification of systems and its application to modelling and control. *IEEE Transactions on systems, man and cybernetics – Part C*, vol.15, n°. 1, pp. 116-132.
- [TSE 05] Tsekouras G., H. Sarimveis, E. Kavakli et G. Bafas. (2005). A hierarchical fuzzy-clustering approach to fuzzy modelling, *Fuzzy sets and systems*, vol. 150, pp. 245-266.
- [VEN 03a] Venkatasubramanian V., R. Rengaswamy, K. Yin et S. N. Kavuri. (2003). A review of process fault detection and diagnosis, Part I : Quantitative model-based methods, *Computer and Chemical Engineering*, vol. 27, pp. 293-311.
- [VEN 03b] Venkatasubramanian V., R. Rengaswamy, S. N. Kavuri et K. Yin. (2003). A review of process fault detection and diagnosis, Part III : Process history based methods, *Computer and Chemical Engineering*, vol. 27, pp. 327-346.
- [WAT 82] Watanabe K. et D.M. Himmelblau. (1982). Instrument fault detection in systems with uncertainties. *International journal of system science*, vol.13, n°.2, pp. 137-158.
- [WEY 00] Weyer E., G. Szederkenyi et K. Hangos. (2000). Grey box fault detection of heat exchangers. *Control engineering practice*, vol.8, pp. 121-131.

-
- [WHI 87] White J.E. et J.L. Speyer. (1987). Detection filter design: spectral theory and algorithms. *IEEE Trans. on automatic control*, 32(7), pp. 593-603.
- [WIL 76] Wilsky A.S. (1976). A survey of design methods for failure detection systems. *Automatica*, vol.12.
- [YAG 94] Yager R.R. et D.P. Filev. (1994). *Essentials of fuzzy modeling and control*. John Wiley and Sons, Inc., USA.
- [YEN 98] Yen J., L. Wang et C. Gillespie. (1998). Improving the interpretability of TSK fuzzy models by combining global learning and local learning. *IEEE Trans. on fuzzy systems*, vol. 6, n°4, pp. 530-537.
- [YEN 03] Yen G.G., L.W. Ho. (2003). Online multiple model based fault diagnosis and accommodation. *IEEE Trans. on industrial electronics*, vol. 50, n°2, pp. 296-312.
- [YIN 97] Ying H. (1997). The Takagi-Sugeno fuzzy controllers using the simplified linear control rules are nonlinear variable gain controllers. *Automatica*, vol.34, n°2, pp. 157-167.
- [YIN 98a] Ying H. (1998). An analytical study on structure, stability and design of general nonlinear Takagi-Sugeno fuzzy control systems. *Automatica*, vol.34, n°12, pp. 1617-1623.
- [YIN 98b] Ying H. (1998). General SISO Takagi-Sugeno fuzzy systems with linear rule consequent are universal approximators. *IEEE Trans. on fuzzy systems*, vol. 6, n°4, pp. 582-586.
- [ZAD 73] Zadeh L. (1973). Outline of a new approach to the analysis of complex systems and decision process. *IEEE Trans. on systems, man and cybernetics – Part C*, vol. 3, n° 1, pp. 28-44.
- [ZHA 94] Zhao J., V. Wertz et R. Gorez. (1994). A fuzzy clustering method for the identification of fuzzy models for dynamic systems. *International symposium on intelligent control*, Ohio, USA, pp. 172-177.
- [ZHA 99] Zhang Q. (1999). *Identification et surveillance de systèmes dynamiques*. Rapport d'habilitation, Université de Rennes 1, France.
- [ZHI 94a] Zhirabok A. N. et A. M. Zhukov. (1994). On the transformations of nonlinear systems. *Proceedings of the ACC, Maryland*, pp. 3570-3571.
- [ZHI 94b] Zhirabok A. N. et O. V. Preobrazhenskaya. (1994). Nonlinear methods for fault detection and isolation in linear systems. *Proceedings of the 33rd CDC, FL*, pp. 3054-3055.