

الجمهورية الجزائرية الديمقراطية الشعبية

REPEBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE BADJI MOKHTAR - ANNABA  
FACULTE DES SCIENCES DE L'INGENIEUR  
DEPARTEMENT D'ELECTRONIQUE



جامعة باجي مختار – عنابة  
كلية علوم الهندسة  
قسم الإلكترونيك

## MEMOIRE

Présenté en vue de l'obtention du diplôme de

## MAGISTER

Thème

*Modélisation et diagnostic de défaillance d'une  
électrovanne pneumatique.*

**Option :**

Commande, détection des défauts et diagnostic des processus  
industriels

**Par**

**M<sup>me</sup> BEDOUD Khouloud**

**Directeur de mémoire : BENSAOULA Salah**

**M.C**

**U.ANNABA**

**DEVENANT LE JURY**

**Président:**

**ABBASSI Hadj-Ahmed**

**Pr**

**U. ANNABA**

**Examineurs :**

**BOULEBTATECHE Brahim**

**Dr**

**U. ANNABA**

**BOUGHAZI Mohamed**

**M.C**

**U. ANNABA**

**DJEDOU Bachir**

**M.C**

**U. ANNABA**

**Année: 2010 / 2011**

# REMERCIEMENT

Mes remerciements les plus distingués s'adressent à :

Mon directeur de mémoire **M<sup>r</sup> S.BENSAOULA**, qui ma beaucoup aidé avec ses idées et ses conseils précieux pour la réalisation de ce modeste travail;

Nos enseignants du département Automatique (de l'institut d'électronique), qui ont assuré notre formation;

Je tiens également à remercier tous les membres de jury ; Tous les membres de ma famille, mes chers parents et mes amies;

Tous ceux qui m'ont soutenu, aidé et encouragé pour arriver au bout de ce projet.

# Résumé

## Résumé

Ce sujet de recherche porte sur le diagnostic de défauts, on s'intéresse particulièrement à développer des algorithmes de décision basés sur la logique floue pour la surveillance des défauts latents qui abrègent la durée de vie de l'installation, voir l'endommager à court terme.

L'installation qui fait l'objet de notre étude est une électrovanne de régulation de flux (jus de betterave) dans les installations de production de sucre. C'est un benchmark (projet DAMADICS) développé par un Consortium de Laboratoires Européen (France, Pologne, Allemagne, etc.), qui a fait l'objet d'intenses recherches notamment en ce qui concerne le diagnostic des défauts brusques par différentes techniques.

Dans une première étape nous exploitons le modèle Simulink de l'actionnaire (électrovanne) proposé par le benchmark, pour générer les résidus obtenus de la comparaison des mesures réelles des variables du processus et les sorties du modèle Simulink, qui seront ensuite analysés par un algorithme de décision basé sur le raisonnement flou. L'objectif d'une telle démarche étant la validation de l'algorithme de décision.

Dans une seconde étape nous construisons un modèle basé sur des mesures réelles produites sur l'installation en cours de production. La technique utilisée est l'optimisation d'un modèle TS. Contrairement à la première étape où le modèle Simulink n'accepte qu'un seul type de défauts à la fois, cette fois-ci on peut injecter plusieurs défauts simultanément.

**Mots Clés :** diagnostic de défaillance, détection de défauts, isolation de défauts.

# Abstract

## **Abstract**

This research topic focuses on the diagnosis of faults, we interested to developing decision algorithms based on fuzzy logic for detection and isolation faults in the DAMADICS actuators; which can minimize damages of the installation, see the damage to short term.

The actuators considered are industrial control valves in the installations of sugar production. It is a benchmark (DAMADICS project) developed by a consortium of European laboratories (France, Poland, Germany, etc..), Which was the subject of intense research in particular as regards the diagnosis of abrupt faults by different techniques .

In a first step we use the Simulink model of the electro- valve proposed by the benchmark to generate residuals obtained by comparing the reels measurements of process variables and model Simulink outputs, which are analyzed by a decision algorithm based on fuzzy reasoning. The objective of this approach is the validation of the decision algorithm for the diagnosis of failure at different levels of intensity.

In a second step we build a model based on actual measurements produced on the installation during production. The technique used is the optimization of a model Narx a neuro-fuzzy architecture. Unlike the first stage or the Simulink model accepts only one type of defects at the same time, this time you can inject several faults simultaneously.

**Key words:** fault isolation, failure diagnosis, fault detection.

# ملخص

## ملخص

إن هذا العمل المقدم يركز على تشخيص الأعطال الممكن حدوثها على صمام إلكتروهوائي. نهتم اهتماما خاصا بتطوير خوارزميات القرار على أساس المنطق المبهم لمراقبة الأخطاء الكامنة التي قد تقصر من عمر المنشأة ، أو تعطيلها على المدى قصير الأجل .

المنشأة التي يتمحور عليها موضوع دراستنا هي صمام إلكتروهوائي للتحكم في التدفق (عصير البنجر) في مرافق إنتاج السكر. إنه **Benshmark** مشروع (DAMADICS) وضعت مجموعة من المختبرات العلمية الأوروبية (فرنسا، بولندا وألمانيا) ، والذي كان موضوع لأبحاث علمية مكثفة خاصة فيما يتعلق بتشخيص الأعطال المفاجئة باستخدام تقنيات مختلفة .

في المرحلة الأولى نقوم باستعمال النموذج **Simulink** للصمام الإلكتروني المقدم من طرف **Benshmark**، لتوليد مخلفات مقارنة القياسات الحقيقية لمتغيرات النظام و مخارج الطراز **Simulink** ، والتي سوف يتم تحليلها فيما بعد من قبل خوارزمية القرار على أساس التحليل المنطقي المبهم . الهدف من هذا المنهج هو المصادقة على قرار الخوارزمية .

في المرحلة الثانية نقوم ببناء نموذج يركز على القياسات الحقيقية المنتجة أثناء الإنتاج. التقنية المستخدمة هي النموذج المثالي من نوع **TS**. على خلاف المرحلة الأولى أين يكون النموذج **Simulink** لا يقبل إلا نوع واحد من الأخطاء في نفس الوقت، هذه المرة يمكن أن نقوم بحقق أخطاء عدة في وقت واحد .

المفاتيح : تشخيص الفشل، كشف الأخطاء، عزل الأخطاء.

## Liste des tableaux

---

1.1 Opérateurs logiques flous les plus utilisés.....	13
3.1 Résultats de détection pour $Z = 6\sigma$ .....	65
3.2 Résultats de détection pour $Z = 3\sigma$ .....	66
3.3 Résultats de détection pour $Z = 2\sigma$ .....	66
3.4 Table de correspondance symptômes/défauts.....	66
3.5 Résultats de détection pour $Z = 6\sigma$ . ....	72
3.6 Résultats de détection pour $Z = 3\sigma$ . ....	72
3.7 Résultats de détection pour $Z = 2\sigma$ . ....	72
4.1 Paramètres des conséquent du modèle flou TS pour X (K+1).....	90
4.2 Paramètres des conséquent du modèle flou TS pour F (K+1).....	90
4.3 Centres des classes du modèle flou TS pour X (K+1).....	91
4.4 Centres des classes du modèle flou TS pour F (K+1).....	91
4.5 Performance numérique du modèle flou TS.....	93
4.6 Performances globales du modèle.....	93

# Liste des figures

---

1.1. Ensemble flou.....	6
1.2. Comparaison ensemble classique – ensemble flou.....	7
1.3. Exemple d’une variable linguistique avec trois termes linguistique.....	8
1.4. Différentes forme de fonction d’appartenance.....	9
1.5. L’intersection.....	11
1.6. L’union.....	12
1.7. Le complément.....	12
1.8. Représentation interne d’un système flou.....	14
1.9. Exemple de fuzzification.....	16
1.10. a) moyenne des maximums, b) centre de gravité.....	19
1.11. Méthodes de diagnostic.....	25
1.12. La redondance matérielle.....	26
1.13. Méthode du modèle.....	27
1.14. Méthode d’identification de paramètres.....	27
1.15. Méthode d'estimation du vecteur d'état.....	28
2.1. Régulation de flux de jus de betterave dans l'usine de sucre.....	33
2.2. Structure de l’électrovanne de régulation.....	34
2.3. Schéma du contrôleur du positionneur.....	35
2.4. Variables d’entrées/sorties de l’actionnaire.....	37
2.5. Modèle entrée-sortie de l’électrovanne.....	37
2.6. Représentation des défauts brusques.....	39
2.7. Représentation des défauts progressifs.....	39
2.8. Blocks Simulink de DABLIB.....	40
2.9. Principe de simulation.....	41
2.10. Simulation d’un bruit blanc.....	42
2.11. Caractéristiques du bloc FGEN.....	42
2.12. Le bloc FSEL.....	43
2.13. Approximation par un modèle Takagi-Sugeno.....	46
2.14. Principe de la méthode FDI.....	49
2.15. Principe de génération de résidus.....	50
2.16. Principe de localisation floue.....	52
3.1. La fonction d’appartenance trapézoïdale.....	54

## Liste des figures

---

3.2 : Fuzzification du résidu.....	55
3.3. Histogrammes des (a) : résidus F et (b) : résidus X pour un système sain.....	56
3.4. Les fonctions d'appartenances pour les deux résidus resF et resX.....	57
3.5 : Résultats de simulation pour un modèle sans défaut.....	58
3.6 : Evaluation floue du signal résidu.....	59
3.7 : Evaluation floue du $i^{\text{eme}}$ résidu. ....	60
3.8 : Simulation de résidus X et F provoqué par le défaut f10 d'intensité = 30%.....	63
3.9: Détection et localisation des défauts.....	67
3.10: Histogramme de resF avec f19=90%.....	68
3.11: Histogramme de resX avec f19=90%.....	68
3.12 : Simulation de resx et resF pour un système sain avec CV-10%.....	70
3.13 : Simulation de resF et resX pour un système sain avec CV+10% .....	71
4.1 : <b>(a)</b> raisonnement flou- <b>(b)</b> Réseau ANFIS lié au modèle TSK.....	75
4.2 : Génération des fonctions d'appartenance par projection de X (k+1).....	88
4.3 : Génération des fonctions d'appartenance par projection de F (k+1).....	89
4.4 : Test de validation du modèle flou TS de flue.....	92
4.5 : Test de validation du modèle flou TS de déplacement.....	92

## *Table des matières*

---

<b>Introduction générale</b> .....	1
<b>Chapitre I : Introduction à la logique floue et au diagnostic industriel</b>	
I.1. Objectifs poursuivis.....	3
I.2. Historique de la logique floue.....	4
I.3. Nécessite de la logique floue.....	4
I.4. Les ensembles flous.....	6
I.4.1. Introduction.....	6
I.4.2. Variable linguistiques.....	8
I.4.3. Fonction d'appartenance.....	9
I.4.4. Propriétés des ensembles flous.....	10
I.4.5. Opération sur les ensembles flous.....	11
I.5. Structure générale d'un système d'inférence flou.....	14
I.5.1. La fuzzification.....	15
I.5.2. Règles floues.....	16
I.5.3. Les étapes du raisonnement flou et inférence flou.....	17
I.5.4. La defuzzification.....	18
I.5.4.1. Méthode du centre de gravite (COG).....	18
I.5.4.2. Méthode moyenne des maximums (MM) .....	19
I.6. Différents types de modèles flous.....	20
I.6.1. Modèle flou mamdani.....	20
I.6.2. Modèle flou relationnel.....	21
I.6.3. Modele flou takagi-sugeno (TS).....	22
II.7. Diagnostic industriel .....	22
II.7.1. Defintions. ....	22
II.7.2. Classifications des méthodes de diagnostic.....	25
II.7.2.1. Méthode de diagnostic par redondance matérielle.....	26
II.7.2.2. Les méthodes internes et les méthodes externes.....	26
II.7.2.3. Les méthodes inductives et les méthodes déductives.....	30
<b>Chapitre II: Benchmark de l'électrovanne et outils de simulation</b>	
II.1. Introduction.....	32
II.2. Description de l'electro-vanne.....	32

## Table des matières

---

II.3. Les défauts.....	37
II.3.1. Description des défauts.....	37
II.3.2. Modes de défaillances.....	38
II.3.2.1. Défaut brusque.....	39
II.3.2.2. Défaut progressif.....	39
II.4. Modèle simulink de l'electro-vanne.....	40
II.5. Modélisation flou de type TAKAGI-SUGENO. ....	43
II.6. La méthode FDI.....	49
II.6.1. Introduction.....	49
II.6.2. Génération de résidus.....	50
II.6.3. Principe de détection.....	51
II.6.4. Localisation.....	51
<b>Chapitre III :</b>	<b>Modèle Simulink pour le diagnostic par raisonnement floue</b>
III.1. Introduction.....	53
III.2. Méthode de détection.....	53
III.2.1. Principe d'évaluation du résidu.....	54
a) Génération des résidus.....	58
b) Evaluation des résidus.....	59
III.3. Méthode d'isolation.....	64
III.4. Application.....	65
III.5. Commentaires .....	66
III.6. Influence de CV.....	69
III.7. Conclusion.....	73
<b>Chapitre IV :</b>	<b>modélisation neuro-floue</b>
IV.1. Introduction.....	74
IV.2. Apprentissage du modèle TS.....	74
IV.3. Construction du modèle TS.....	76
IV.4. Modélisation basée sur des techniques de coalescence floue.....	77
IV.4.1. Introduction.....	77
IV.4.2. Algorithme de clustering flou .....	79

## *Table des matières*

---

IV.4.3. Estimation des paramètres par les moindres carrés.....	83
IV.4.4. Validation du modèle .....	85
IV.5. Application .....	86
IV.5.1. Sélection des données et des variables.....	86
IV.5.2. Utilisation du clustering flou GK .....	87
IV.6. Conclusion.....	94
Conclusion générale .....	95
Référence bibliographique.....	97

# Introduction générale

## **Introduction générale :**

Aujourd'hui, il existe une demande croissante sur des systèmes dynamiques plus sûrs et plus fiables. Ces exigences s'étendent vers des processus industriels qui sont essentiellement contrôlés par des électrovannes de régulation de débit. Prenant en considération que le mauvais fonctionnement d'une vanne dans de nombreuses applications critiques peut entraîner de graves conséquences. Le diagnostic de pannes industrielles des électrovannes de régulation est une tâche très importante, lorsque le défaut est détecté et isolé, une réponse rapide pourrait empêcher le système de subir des coûteux dommages, perte d'efficacité et de productivité.

En effet, le processus du diagnostic industriel repose sur le principe de l'observation et de l'analyse des symptômes d'une défaillance, dans le but de trouver le remède garantissant sa réparation et réduire sa probabilité de défaillance. Le problème du diagnostic industriel se ramenant par définition au problème inverse entre les causes et les effets. Une connaissance intime des différents phénomènes régissant les matériels des systèmes industriels est absolument indispensable pour entreprendre le diagnostic d'une défaillance.

Dans ce mémoire, on cherche à détecter et isoler le maximum possible de défauts qui peuvent apparaître en tenant compte de l'intensité du défaut. Le développement d'algorithmes de décision basés sur la logique floue pour la surveillance des défauts, est une façon de surmonter le problème de détection et d'isolation en l'absence d'un modèle analytique. Le principal avantage de la logique floue est qu'elle permet de désigner le comportement du système par des relations "si-alors".

Afin de générer des résidus ou indicateurs de défauts, nous utilisons le modèle Simulink proposé par le Benchmark pour comparer les signaux du modèle et les signaux réelles disponibles, qui seront ensuite analysés par un algorithme de décision. Mais ce modèle Simulink n'accepte qu'un seul type de défauts à la fois. Pour cette raison, on cherche à modéliser le système étudié par l'optimisation d'un modèle floue type Takagi-Sugeno (TS). Contrairement à la première étape, cette fois-ci on peut injecter plusieurs défauts simultanément.

# Introduction générale

Le formalisme TS est mieux adapté à une démarche plus systématique pour la construction de modèles non linéaires multi-variable, grâce à leur bonne capacité d'interpolation numérique et d'apprentissage à partir des données.

Ce travail est réparti en quatre chapitres, le premier chapitre présente une profonde définition sur la logique floue et les différentes méthodes de diagnostic industriel, le deuxième chapitre consiste à faire une description générale sur le système étudié et le principe de modélisation type TS, le troisième chapitre consacré au développement des algorithmes de décision, quant au quatrième chapitre il présente la modélisation floue type TS, qui sert de modèle pour le diagnostic de défaut.

- ▶ **Chapitre I :** nous présentons une étude théorique sur : la logique floue, le diagnostic industriel et la classification des méthodes de diagnostic.
- ▶ **Chapitre II :** donne un aperçu sur le benchmark de l'électrovanne; la modélisation floue de type TS et le principe de la méthode FDI.
- ▶ **Chapitre III :** nous avons tout d'abord décrit le principe de la méthode FDI, ensuite nous avons décrit en détail les étapes nécessaires pour la réalisation d'un système d'aide au diagnostic, basé sur le raisonnement floue en exploitant le modèle Simulink de l'électrovanne proposé par le Benchmark.
- ▶ **Chapitre VI :** porte sur la modélisation neuro-floue pour la réalisation d'un modèle floue de l'électrovanne type TS. Finalement, nous achevons notre travail par une conclusion générale et quelques perspectives pour les travaux de recherche futurs.

- I.1. Objectifs poursuivis.
- I.2. Historique de la logique floue.
- I.3. Nécessite de la logique floue.
- I.4. Les ensembles flous.
  - I.4.1. Introduction.
  - I.4.2. Variable linguistiques.
  - I.4.3. Fonction d'appartenance.
  - I.4.4. Propriétés des ensembles flous.
  - I.4.5. Opération sur les ensembles flous.
- I.5. Structure générale d'un système d'inférence flou.
  - I.5.1. La fuzzification.
  - I.5.2. Règles floues.
  - I.5.3. Les étapes du raisonnement flou et inférence flou.
  - I.5.4. La defuzzification.
    - I.5.4.1. Méthode du centre de gravite (COG).
    - I.5.4.2. Méthode moyenne des maximums (MM).
- I.6. Différents types de modèles flous.
- II.7. Diagnostic industriel.
  - II.7.1. Définitions.
  - II.7.2. Classifications des méthodes de diagnostic.
    - II.7.2.1. Méthode de diagnostic par redondance matérielle.
    - II.7.2.2. Les méthodes internes et les méthodes externes.
    - II.7.2.3. Les méthodes inductives et les méthodes déductives.

## I.1. Objectifs poursuivis:

Cette étude s'intéresse à une électrovanne en tant que système de régulation d'un liquide. Cet actionnaire est installé dans une unité de production de sucre à partir du jus de betterave. L'identification du modèle de ce système, ainsi que le diagnostic des défauts sont basés sur des mesures réelles de variables physiques de l'électrovanne. Notre but est le diagnostic de défaut brusque avec des méthodes issues de la théorie de la logique floue. La localisation du défaut permet à l'opérateur d'intervenir en temps réel pour sa réparation, dans ce cas la réaction de l'algorithme de diagnostic doit être rapide. Ce type d'algorithme est d'autant plus rapide que la complexité des calculs est moindre; il nous faut donc des modèles simples avec très peu de paramètres. Notre approche à ce problème de diagnostic est la mise en œuvre d'algorithmes basés sur la logique floue, ce choix est justifié par la complexité du modèle analytique de l'électrovanne. Pour mener cette recherche sur le diagnostic de défaut brusque, on utilise le benchmark de l'électrovanne développé dans le cadre du projet DAMADICS.

Dans une première étape nous exploitons le modèle Simulink de l'électrovanne. Ce modèle reçoit en entrée des mesures réelles de l'installation en fonctionnement normale; on simule alors un défaut et on obtient en sortie des résidus, qui sont ensuite analysés par un algorithme de décision basé sur un raisonnement flou. L'objectif d'une telle démarche est la validation de l'algorithme de décision pour le diagnostic de défaut à différents niveaux d'intensités. Dans une seconde étape on construit un modèle basé sur des mesures réelles produites sur l'installation en cours de production. La technique utilisée est l'optimisation d'un modèle de type Takagi-Sugeno NARX (TS NARX). Contrairement à la première étape où le modèle Simulink n'accepte qu'un seul type de défaut à la fois, la modélisation TS NARX permet la simulation de défauts multiples. L'intérêt de cette deuxième étape étant le développement d'un algorithme FDI pouvant être implémenté sur un PC industriel.

On cherche à ce que l'algorithme puisse reconnaître un défaut le plus tôt possible avec un risque d'erreur minimum, ceci constitue une aide à l'opérateur pour une réparation rapide du défaut. Lorsque des défauts ont le même symptôme leur isolation est difficile, l'algorithme doit pouvoir signaler à l'opérateur l'origine la plus probable du défaut.

## I.2. Historique de la logique floue:

Au départ la théorie de la logique floue, s'affirmait comme une technique opérationnelle. Utilisée à côté d'autres techniques de contrôle avancé, elle fait une entrée discrète mais appréciée dans les automatismes de contrôle industriel. Les bases théoriques de la logique floue ont été établies au début des années 1965 par le professeur **Lotfi Zadeh** de l'université Berkeley de Californie [1], cette technique associe les notions de « sous-ensemble flou » et de « théorie des possibilités ». En 1970, c'était la première application de la logique floue dans les systèmes experts d'aide à la décision en médecine, puis en 1975 Mamdani a réalisé une régulation floue d'une chaudière à vapeur. Les Japonais [2], en 1985 étaient les premiers à avoir utilisé la logique floue dans les produits grand public « Fuzzy Logic Inside ».

## I.3. Nécessité de la logique floue:

Construire un modèle mathématique permet de mieux comprendre et de prévoir l'évolution du processus réel étudié au cours du temps. Cette tâche est nécessaire pour la synthèse de modules de commande, de supervision et de diagnostic efficace et doit permettre de reproduire le plus exactement possible la réalité. La modélisation basée sur les outils mathématiques conventionnels (équations différentielles) ne peut être utilisée dans les systèmes incertains. Il existe trois grandes classes de modèles largement utilisées dans l'industrie. L'application visée est souvent déterminante dans le choix du modèle approprié. Ces trois classes de modèles sont [3] [4] :

- **Les modèles « boîtes blanches »** : sont réalisés grâce à la compréhension de tous les phénomènes naturels intervenant dans le système étudié. Il s'agit donc de poser les équations différentielles traduisant la dynamique du système à partir des lois tirées de la physique. Ces modèles permettent parfois d'atteindre une grande précision, mais ils sont très longs à mettre au point pour des systèmes complexes. Ils peuvent demander très vite une grande capacité de calculs et deviennent alors difficilement implémentables en temps réel dans des modules de supervision et de diagnostic.
- **Les modèles « boîtes noires »** : sont utilisées lorsque le comportement physique du processus n'est pas disponible ou nos connaissances sur celui-ci sont rudimentaires.

Les processus industriels sont de nature non linéaires en générale, et les modèles sont obtenus par identification expérimentale du procédé. Ils donnent une approximation linéaire globale de sa dynamique. L'opération consiste à déterminer un modèle du système à partir des mesures entrées/sorties traitées soit par des méthodes tirées de la modélisation statistiques des signaux, ou bien par des méthodes dites « intelligentes ». Le domaine des techniques employées pour décrire le modèle est très large, il s'étend de la régression non-paramétrique, aux structurées tels que les réseaux de neurones, et les modèles neuro-flous.

➤ **Les modèles « boîtes grises »** : sont des modèles « hybrides ». Les parties connues sont décrites à l'aide de boîtes « blanches » et les parties moins connues sont décrites par des boîtes « noires ». Ainsi les modèles mathématiques (Integro-différentiels) n'apportent pas la possibilité de quantifier des connaissances approximatives et subjectives décrivant des processus physiques. De ce fait, le savoir-faire de l'expert reste le recours privilégié pour le pilotage de systèmes complexes, peu connus et fortement non linéaires. La modélisation de tels systèmes est largement facilitée par l'utilisation de concepts tels que : les réseaux de neurones et la logique floue. La logique floue est dite aussi logique linguistique car ses valeurs de vérité sont des mots du langage courant, elle n'est pas une logique imprécise mais bien une logique qui s'adapte à l'être humain. La logique floue est un outil pour intégrer des connaissances humaines dans des algorithmes pratiques. Elle a l'avantage de combiner le traitement de donnée numérique et symbolique.

Les méthodes de logique floue peuvent être utilisées pour concevoir des systèmes de diagnostic intelligents [5] sur la base de connaissances exprimées dans un langage naturel. Il s'agit d'une approche calquée sur le raisonnement humain plutôt que sur des calculs rigides. En effet, le mode de raisonnement en logique floue est plus intuitif que la logique classique. Il permet aux concepteurs de mieux appréhender les phénomènes naturels, imprécis et difficilement modélisables en s'appuyant sur la définition de règles et de fonctions d'appartenance à des ensembles dits « ensembles flous » [1][6].

Un domaine d'application de la logique floue qui devient fréquent est celui du réglage et de la commande des régulations industrielles. Cette méthode permet d'obtenir une loi de commande souvent efficace, sans devoir faire appel à des développements théoriques importants. Elle présente l'intérêt de prendre en compte les expériences acquises par les

utilisateurs et opérateurs du processus à commander. Les éléments de base de la logique floue sont [3][6]:

- ✓ Les variables linguistiques
- ✓ Les fonctions d'appartenance
- ✓ Les déductions aux inférences : Prise de décision à partir d'une base de règles  
**Si...Alors**


## I.4. Les ensembles flous:

### I.4.1 Introduction:

La théorie des ensembles floue est une théorie mathématique, elle a été introduite par Lotfi Zadeh en 1965, qui a montré que cette théorie est un cas particulier de la théorie des sous ensembles classiques où les fonctions d'appartenance considérées prennent des valeurs binaires ( $\{0,1\}$ ) [2].

La notion d'ensemble flou a pour but de permettre l'idée d'une appartenance partielle d'un élément à un ensemble ou à une classe, c'est-à-dire d'autoriser un élément à appartenir plus ou moins fortement à cette classe [4]. Cette notion permet l'utilisation de catégories de données aux limites mal définies, de situations intermédiaires entre le tout et le rien, le passage progressif d'une propriété à une autre, etc...

Soit l'ensemble  $U$  des valeurs de la variable  $x$ , appelé l'univers du discours; un sous-ensemble  $A$  de  $U$  et une fonction  $\mu_A(x)$  comprise entre 0 et 1. Cette fonction  $\mu_A(x)$  quantifie le degré avec lequel chaque élément  $x$  de  $U$  appartient à  $A$ .



**Fig.1.1** : Ensemble flou.

U : l'univers du discours.

A : sous-ensemble de U.

-Si  $\mu_A(x) = 1$  x appartient complètement au sous-ensemble  $A_i$

-Si  $\mu_A(x) = 0$  x n'appartient pas au sous-ensemble A

-Si  $0 < \mu_A(x) < 1$  x appartient partiellement au sous-ensemble A

Le sous-ensemble A est donc un ensemble flou et  $\mu_A(x)$  est appelé fonction d'appartenance.

La figure 1.2 permet de mieux comprendre la notion d'ensemble flou par rapport à un ensemble classique.

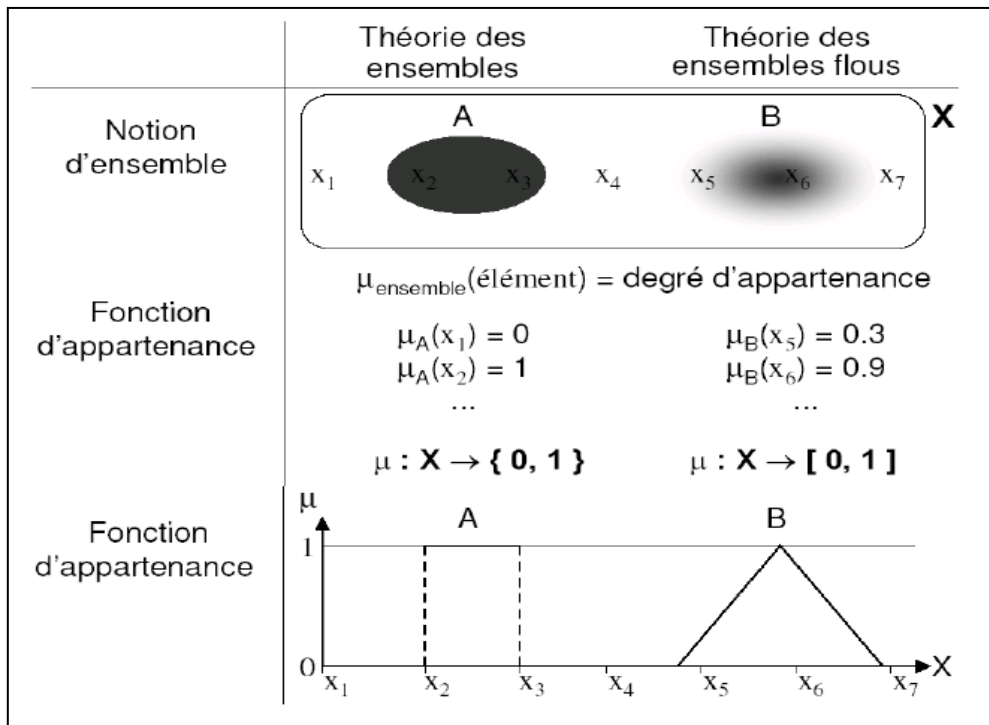


Fig. 1.2 : Comparaison ensemble classique – ensemble flou.

L'équation (1-1) définit un ensemble flou complètement décrit par sa fonction d'appartenance  $\mu_A(x)$ .

$$A = \{(x, \mu_A(x)) / x \in U\} \tag{1-1}$$

Dans le cas d'un ensemble discret  $U = \{x_i / i = 1, 2, \dots, n\}$ , un ensemble flou A peut être défini par une liste de paires ordonnées: degré d'appartenance/élément de l'ensemble :

$$A = \{ \mu_A(x_1)/x_1, \mu_A(x_2)/x_2, \dots, \mu_A(x_n)/x_n \} \quad (1-2).$$

On utilise souvent une formalisation vectorielle, plus commode pour la programmation:

$$x = [x_1, x_2, \dots, x_n]^T, \mu = [\mu_A(x_1), \mu_A(x_2), \dots, \mu_A(x_n)]^T \quad (1-3).$$

#### I.4.2. Variable linguistique:

Une variable linguistique est une variable dont les valeurs associées sont linguistiques plutôt que numérique. La variable linguistique est caractérisée par un ensemble décrit par [3] [4] :

$\{x, T(x), U, G, M\}$ , avec :

$x$  : nom de la variable de base.

$T(x)$  : ensembles des valeurs linguistiques que peut prendre  $x$ .

$U$  : l'univers du discours associé avec la variable de base.

$G$  : la règle syntaxique pour générer les valeurs linguistiques de  $x$ .

$M$  : la règle sémantique pour associer un sens à chaque valeur linguistique  
(ensemble flou dans  $U$ ).

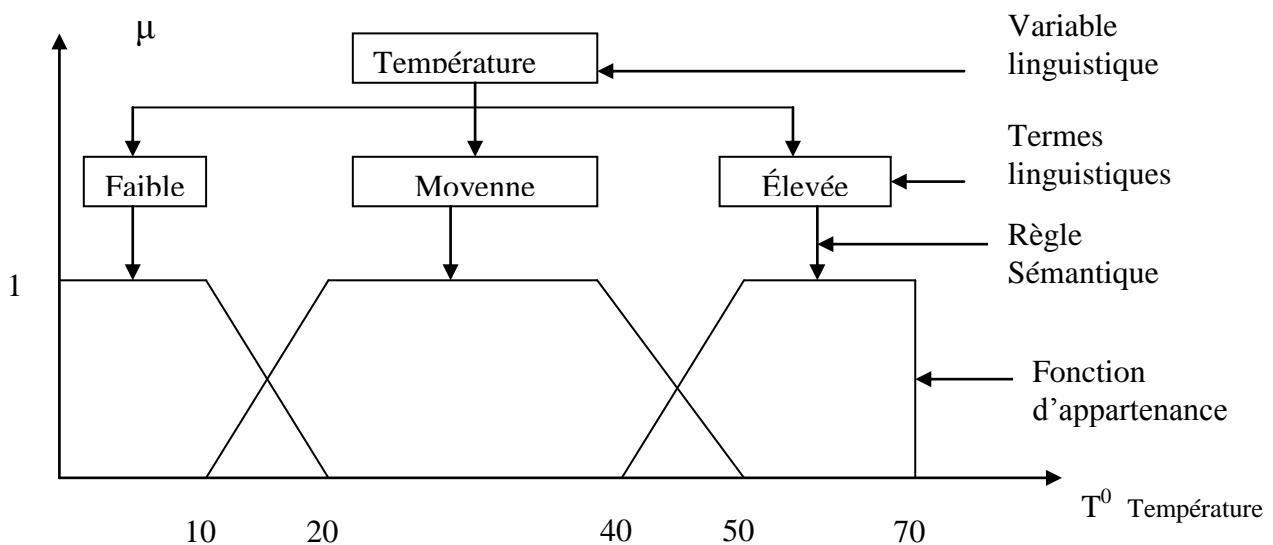
Exemple (1.1) : Prenons comme exemple la variable linguistique température où :

Univers du discours  $U$ : gamme de température de 0°C à 70°C.

Variable linguistique  $x$ : la température.

Valeurs linguistiques  $T(x)$ : « Faible » « Moyenne » « Elevée ».

Règle syntaxique  $G$  : Si  $20 < T < 40$  alors température moyenne.



**Fig. 1.3** : Exemple d'une variable linguistique avec trois termes linguistique.

La température ambiante (variable de base) peut être définie avec un ensemble de termes  $T(x) = \{ \text{Faible, Moyenne, Elevée} \}$ , le terme Faible représente une valeur linguistique.

### I.4.3. Fonction d'appartenance:

La fonction d'appartenance mesure le degré avec lequel un élément  $x$  appartient à un ensemble flou  $A$ . elles sont soit de distribution uniforme ou aléatoire [1] [3]. Les fonctions d'appartenance peuvent avoir plusieurs formes :

- ▶ Triangulaire.
- ▶ En forme de cloche.
- ▶ Monotone (croissante ou décroissante).
- ▶ Trapézoïdale.




Fig. 1.4 : Différentes formes de fonction d'appartenance.

L'allure de la fonction d'appartenance est à choisir selon l'application traitée. Cependant, pour un ensemble flou, ce qui importe est moins la valeur précise des degrés d'appartenance des éléments du support que l'ordonnement de ces degrés d'appartenance entre eux.

Les fonctions d'appartenance les plus utilisées sont en forme de trapèze ou de triangle, et permettent de respecter cette contrainte tout en gardant une forme analytique très simple. Dans certaines applications, où l'on doit dériver la fonction d'appartenance, on choisira plutôt des fonctions en  $S$  ou des fonctions de type gaussienne, continûment dérivables sur leur support.

**I.4.4. Propriétés des ensembles flous:** [1] [4]**➤ Egalité:**

Deux ensembles flous  $A$  et  $B$  de  $U$  sont égaux si leurs fonctions d'appartenance prennent la même valeur pour tout élément de  $U$  :

$$\forall x \in U : \mu_A(x) = \mu_B(x) \quad (1-4).$$

**➤ Inclusion:**

Un ensemble flou  $A$  est inclus dans un ensemble flou  $B$  si toutes ses valeurs de fonction d'appartenance sont inférieures à celles de  $B$  sur tout le domaine  $U$ .

$$\forall x \in U : \mu_A(x) \leq \mu_B(x) \quad (1-5).$$

**➤ Support:**

Le support est un sous-ensemble de l'univers de discours  $U$  pour lequel la fonction d'appartenance de ses éléments n'est pas nulle.

$$\text{Supp}(A) = \{ \forall x \in U / \mu_A(x) \neq 0 \} \quad (1-6).$$

**➤ Hauteur:**

La hauteur d'un ensemble flou  $A$  est la valeur max, de la fonction d'appartenance sur le domaine  $U$ . l'ensemble flou  $A$  est dit normal si  $h(A)=1$ .

$$h(A) = \max_{x \in U} \mu_A(x) \quad (1-7).$$

**➤ Noyau:**

Le noyau d'un ensemble flou  $A$  est un sous-ensemble de l'univers de discours  $U$  qui contient tous les éléments qui appartiennent à  $A$  avec un degré d'appartenance qui est égal à 1.

$$\text{Core}(A) = \{ \forall x \in U / \mu_A(x) = 1 \} \quad (1-8).$$

**➤ Cardinal:**

Le cardinal d'un ensemble flou discret  $A = \{ \mu_A(x_1)/x_1, \mu_A(x_2)/x_2, \dots, \mu_A(x_n)/x_n \}$  est la

$$\text{somme des fonctions d'appartenance } |A| = \text{Card}(A) = \sum_{x \in U} \mu_A(x) \quad (1-9).$$

➤ **Partition floue:**

Soit  $N$  ensembles flous  $A_j$  du référentiel  $U$ ,  $(A_1, A_2, \dots, A_j, \dots, A_N)$  est dite une partition floue si :

$$\forall x \in U, \sum_{j=1}^N \mu_{A_j}(x) = 1, \text{ avec } A_j \neq \emptyset, \text{ et } A_j \neq U \quad \forall 1 \leq j \leq N \quad (1-10).$$

qui énonce que pour chaque  $x$ , la somme des degrés d'appartenance soit égale à 1.

➤  **$\alpha$ -coupe:**

$A_\alpha$  d'un ensemble flou  $A$  est un sous-ensemble de l'univers de discours  $U$  telle que la fonction d'appartenance de ses éléments est supérieur ou égal à  $\alpha$  :

$$A_\alpha = \{ \forall x \in U / \mu_A(x) \geq \alpha \} \text{ avec } \alpha \in [0, 1] \quad (1-11).$$

#### I.4.5. Opérations sur les ensembles flous:

Au niveau des inférences les variables linguistiques sont liées entre elles par des opérateurs 'ET' et 'OU'. Ce sont des opérateurs de la logique floue qui interviennent sur des fonctions d'appartenance attribuées aux variables linguistiques [4], d'autre part il existe l'opérateur NON (inverse). Les opérateurs 'ET' et 'OU' sont souvent réalisés par les opérations 'MIN' et 'MAX'. Les opérateurs logiques de conjonction (intersection), disjonction (union) et négation (complément) peuvent être utilisés afin de construire une proposition floue composée. Nous présentons les opérateurs les plus utilisés parmi les nombreux disponibles en logique floue.

❖ **L'intersection :** L'opérateur 'ET' correspond à l'intersection de deux ensembles

$$A \text{ et } B : \mu_{A \cap B} = \min \{ \mu_A(x), \mu_B(x) \}. \quad (1-12).$$




Fig. 1.5 : L'intersection.

❖ **L'union** : L'opérateur 'OU' correspond à l'union de deux ensembles A et B

$$\mu_{A \cup B} = \max \{ \mu_A(x), \mu_B(x) \}. \quad (1-13).$$




Fig.1.6 : L'union.

❖ **Le complément** : Selon la théorie des ensembles flous, l'opérateur 'NON' correspond à l'ensemble complémentaire

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x). \quad (1-14).$$




Fig. 1.7 : Le complément.

Exemple (1.2) :

Ces opérateurs interviennent dans des règles qui expriment les connaissances de l'expert. Ces règles établissent des relations entre variables floues. Soit la règle  $R_i$  tel que :

$$R_i : \text{Si } x_1 \text{ est } A_{i1} \text{ et } x_2 \text{ est } A_{i2} \text{ ou } x_3 \text{ n'est pas } A_{i3} \text{ Alors } y \text{ est } B_i \quad (1-15).$$

Les ensembles flous [6] unidimensionnels  $A_i$  sont définis pour chaque composant du vecteur antécédent. Le degré d'accomplissement  $\beta_i$  de la règle est alors calculé en employant les opérateurs d'intersection, d'union et de complément approprié, par exemple :

$$\beta_i = \mu_{A_{i1}}(x_1) \wedge \mu_{A_{i2}}(x_2) \vee (1 - \mu_{A_{i3}}(x_3)) \quad (1-16).$$

où l'opérateur minimum ( $\wedge$ ) représente dans ce cas la conjonction (ET), l'opérateur maximum ( $\vee$ ) représente la disjonction (OU), et le complément représente la négation (NON). Néanmoins, la généralisation des opérations d'union et d'intersection ensembliste classique aux sous-ensembles flous n'est pas définie de manière unique. Il existe, en fait, une multitude d'opérateurs de disjonction et de conjonction utilisée dans les propositions floues. Ces opérateurs sont regroupés en deux familles : les normes triangulaires, notées t-normes, qui définissent les opérateurs d'intersection ou de conjonction et les conormes triangulaires, notées t-conormes ou s-normes, qui définissent les opérateurs d'union ou de disjonction. De manière générale ces opérateurs sont des fonctions définies dans l'espace :  $[0, 1] \times [0, 1] \rightarrow [0, 1]$ , mais elles ont des propriétés distinctes qui vont influencer le type de raisonnement approché. Le Tableau. 1.1 regroupe quelques définitions de t-normes et t-conormes duales utilisées fréquemment [4]:

t-norme : $t(x,y)$ (intersection floue)	t-conorme : $s(x,y)$ (union floue)	Nom
$\min(x,y)$	$\max(x,y)$	Min et max de Zadeh
$x \cdot y$	$x + y - x \cdot y$	Produit et somme algébrique (Bandler)
$\max(0, x + y - 1)$	$\min(1, x + y)$	Produit et somme bornés (Lukasiewicz)

**Tableau 1.1** : Opérateurs logiques flous les plus utilisés.

### I.5. Structure générale d'un système d'inférence flou:

Un système d'inférence floue FIS (Fuzzy Inference System) est formé de cinq blocs fonctionnels [3] [4] comme indiqué sur la figure 1.8.

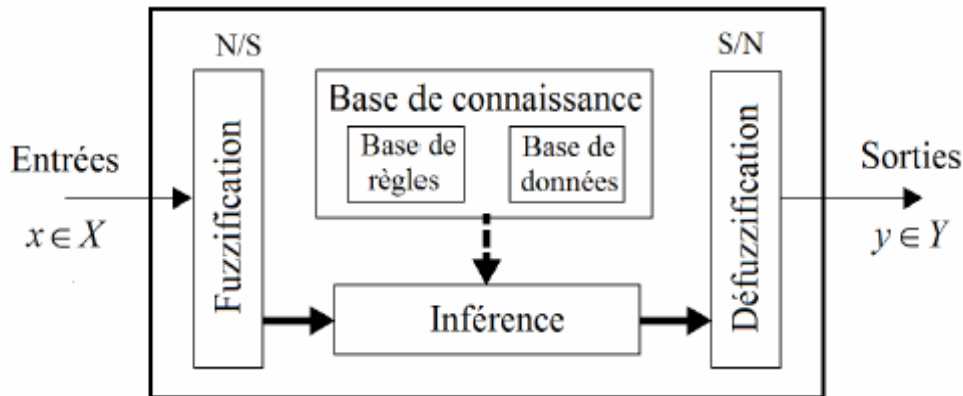


Fig.1.8 : Représentation interne d'un système flou.

Le premier bloc est l'étage de fuzzification qui transforme les valeurs numériques en degrés d'appartenance aux différents ensembles flous de la partition. Le second bloc est le moteur d'inférence constitué de l'ensemble des règles et la base de données. En sortie, l'étage de défuzzification permet si nécessaire, d'inférer une valeur nette, utilisable en commande par exemple, à partir du résultat de l'agrégation des règles.

Les systèmes flous basés sur des règles du type « **Si... Alors** » ont des antécédents et des conséquents qui sont spécifiés de manière symbolique. Dans le cadre de la modélisation et la commande de systèmes, l'exploitation d'une telle connaissance nécessite en général la mise en place d'interfaces numérique/symbolique (N/S) et symbolique/numérique (S/N). Ces dernières sont en effet des passerelles indispensables à l'établissement d'un lien entre l'ensemble de règles (base de règles) qui interfacent le système flou et le procédé, sur lequel seules des mesures et des actions numériques sont envisageables. De manière classique, le fonctionnement interne des systèmes flous repose sur une structure, représentée sur la figure 1.8, qui inclut:

- Une base de règles contenant un nombre de règles **Si... Alors** de la stratégie de commande de l'expert; et une base de données qui regroupe l'ensemble des définitions utilisées dans la commande floue (univers de discours, partitions floues, choix des opérateurs...).

- Une unité de décision (Inférence) qui transforme les opérations d'interférences en règles à partir d'une base de connaissance (fournie par l'expert) et du sous-ensemble flou correspondant à la fuzzification du vecteur de mesure. En général, plusieurs valeurs de variables floues, convenablement défini par des fonctions d'appartenance, sont liées entre elles par des règles, afin de tirer des conclusions. On parle alors de déductions floues. Dans ce contexte, on peut distinguer deux genres de règles d'inférences:

- Inférence avec plusieurs règles
- Inférence avec une seule règle.

Dans le cas d'une inférence avec plusieurs règles, celles-ci s'expriment sous la forme générale:

Si condition 1, Alors opération 1, OU  
 Si condition 2, Alors opération 2, OU  
 Si condition 3, Alors opération 3, OU  
 .....  
 Si condition m, Alors opération m,

Les conditions peuvent dépendre d'une ou de plusieurs variables.

Dans le deuxième cas, les variables sont liées entre elles par des opérateurs flous Et et OU. A chaque variable sont attribuées des fonctions d'appartenance, tenant compte des ensembles flous formés par ces variables.

- Une interface de fuzzification qui transforme les entrées crisp en degrés de vérification des valeurs linguistiques.
- Finalement, une interface de défuzzification, avec éventuellement un post-traitement d'information qui transforme les résultats flous d'inférence en une sortie crisp.

### **I.5.1. La fuzzification:**

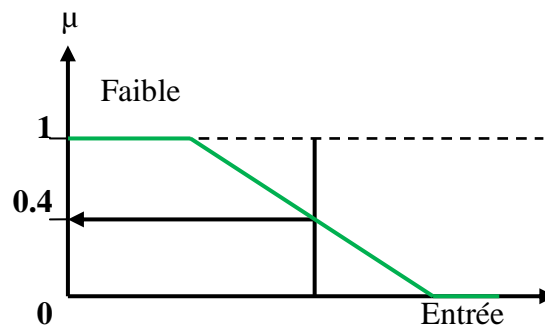
La fuzzification est l'étape de passage du domaine numérique au domaine symbolique (flou). Cette étape est nécessaire dès lors que nous voulons manipuler à l'aide de la théorie des ensembles flous des grandeurs physiques mesurables (précises ou imprécises). Suivant l'application, la fuzzification peut se faire de différentes manières. Cela peut consister à

transformer les données numériques en valeurs linguistiques [6] afin de donner un avis subjectif sur l'état du système observé. Il est nécessaire de transformer les variables non floues provenant du monde extérieur en sous-ensembles flous. Pour se faire, on utilise un opérateur dit de fuzzification qui associe à une mesure une fonction d'appartenance particulière. Les systèmes à logique floue traitent de variables d'entrées floues et fournissent des résultats sur des variables de sorties elles-mêmes floues. Pour fuzzifier, il faut donner [7] :

- 1 / L'univers du discours (Plage de variations possibles de l'entrée considérée).
- 2/ Une partition en classe floue de cet univers (nombre des ensembles flous).
- 3/ Les fonctions d'appartenances de chacune de ces classes.

Exemple (1.3) :

Si la valeur courante de la variable « entrée » est de 2, le degré d'appartenance à la fonction d'appartenance « entrée faible » est égal à 0,4 qui est le résultat de la fuzzification. La fuzzification des variables est une phase délicate du processus mis en oeuvre par la logique floue. Elle est souvent réalisée de manière itérative et requiert de l'expérience.



**Fig. 1.9 :** Exemple de fuzzification.

### I.5.2. Règles floues:


Les règles d'inférence floue forment le noyau des systèmes flous. Elles expriment un lien entre des propositions floues élémentaires ou des conjonctions de propositions élémentaires sous la forme.

**R :** Si proposition antécédente **Alors** proposition conséquente.

Les systèmes à logique floue utilisent une expertise exprimée sous forme d'une base de règles du type: Si....Alors...                      Si (  $x$  est A ) Alors (  $y$  est B )

- La variable floue  $x$  appartient à la classe floue  $A$  avec un degré de validité  $\mu(x_0)$ .
- La variable floue  $y$  appartient à la classe floue  $B$  à un degré qui dépend du degré de validité  $\mu(x_0)$  de la prémisse.

Exemple (1.4)



Le niveau de précision avec lequel peut être représenté un système donné par un modèle flou est associé avec la granularité du traitement de l'information, qui dépend entre autres, du nombre de termes linguistiques ainsi que de la forme particulière et du degré de chevauchement des fonctions d'appartenance utilisées dans le modèle [7].

### I.5.3. Les étapes du raisonnement flou et inférence flou:

Les étapes du raisonnement flou réalisé par un SIF (Système d'Inférence Flou) sont [4] [7] :

- 1) Projeter les variables d'entrée sur les fonctions d'appartenance dans la partie antécédente pour obtenir les valeurs d'appartenances de chaque valeur linguistique (fuzzification).
- 2) Combiner (à travers un opérateur spécifique Max ou Min) les valeurs d'appartenance dans la partie antécédente pour obtenir la pondération de chaque règle.

Puisque les inférences comportent les opérateurs flous comme l'opérateur 'ET' et 'OU' liant les variables et les règles floues, d'autre part et à cause de l'empiétement des fonctions d'appartenance, deux règles ou plus peuvent être actives en même temps. Donc il faut prévoir une méthode efficace permettant de réaliser les opérations floues dans une inférence, ce qui permet un traitement numérique de cette dernière, on parle de méthode ou mécanisme d'inférence. Les mécanismes d'inférence les plus utilisés sont [3] [7] :

- ✓ Le mécanisme *MIN-MAX*.
- ✓ Le mécanisme *MAX-PROD*.
- ✓ Le mécanisme *SOMME-PROD*.

Exemple (1.5) : Nous allons considérer un système flou avec "n" règles linguistiques.

$$\left\{ \begin{array}{l} \text{Si } x \text{ est } A_1 \text{ ET } y \text{ est } B_1 \text{ Alors } z \text{ est } C_1 \\ \text{Si } x \text{ est } A_2 \text{ ET } y \text{ est } B_2 \text{ Alors } z \text{ est } C_2 \\ \dots \\ \dots \\ \text{Si } x \text{ est } A_n \text{ ET } y \text{ est } B_n \text{ Alors } z \text{ est } C_n \end{array} \right.$$

Où x, y et z sont des variables linguistiques qui représentent les variables d'état du processus et  $A_i$ ,  $B_i$  et  $C_i$  ( $i=1, \dots, n$ ) sont les ensembles flous définis dans les ensembles de référence pour x, y, z respectivement. Au sens mathématique, l'activation d'une règle est l'application de T-normes pour obtenir le poids d'activation (ou degré d'accomplissement) de chaque règle. Alors le poids  $w_i$  obtenue de la  $i^{\text{ème}}$  règle du système précédent est :

$$W_i = \mu_{A_i}(x) \text{ ET } \mu_{B_i}(y) \quad (1-17).$$

- 3) Générer le conséquent qualifié de chaque règle.
- 4) Faire une moyenne pondérée des conséquents qualifiés pour obtenir une sortie crisp (non floue).

#### **I.5.4. La defuzzification:**

L'opération inverse qui permet de passer d'une représentation sous forme de variable linguistique à une variable numérique applicable physiquement s'appelle la défuzzification. Il existe plusieurs méthodes permettant d'obtenir une valeur précise à partir d'un ensemble flou en entrée. On cite comme exemples la moyenne des maxima et le centre de gravité [3] [4]. La défuzzification appelée aussi combinaison des règles est nécessaire lorsque plusieurs règles d'inférence sont validées, car on se retrouve dans ce cas avec plusieurs ensembles flous de sortie, il faut donc appliquer une technique pour trouver une valeur de sortie [7].

##### **I.5.4.1. Méthode du centre de gravite (COG):**

En commande floue, la défuzzification COG est la plus utilisée. La valeur défuzzifiée est donnée dans le cas continue par :

$$y_o = \frac{\int_{y_1}^{y_2} y \mu(y) dy}{\int_{y_1}^{y_2} \mu(y) dy} \quad (1-18).$$

et dans le cas discret par :

$$y_o = \frac{\sum_{i=1}^n \mu_i y_i}{\sum_{i=1}^n \mu_i} \quad (1-19).$$

avec  $n$  : niveau de discrétisation

$y_i$  :  $i^{\text{ème}}$  sortie.

$\mu_i$  : valeur d'appartenance de la  $i^{\text{ème}}$  sortie.

#### I.5.4.2. Méthode moyenne des maximums (MM):

C'est la moyenne des valeurs de sorties les plus vraisemblables. La défuzzification MM est plutôt utilisée lorsqu'il s'agit de discriminer une valeur de sortie (Ex: reconnaissance de formes). Dans le cas discret la valeur défuzzifiée est donnée par :

$$y_o = \sum_{i=1}^L \frac{r_i}{l} \quad (1-20).$$

$l$  : n<sup>bre</sup> de valeurs quantifiées  $r_i$  où l'appartenance est max.




Fig. 1.10 : (a) Moyenne des maximums, (b) Centre de gravité

## I.6. Différents types de modèles flous:

Un modèle de raisonnement flou est généralement constitué d'un ensemble de règles « Si- Alors » qui permettent de représenter les relations entre les variables d'entrée et de sortie dont l'expression générique est de la forme :

**Si** antécédent **Alors** conséquent

Il existe plusieurs modèles qui ont été développés, mais les plus courants sont : le modèle de **MAMDANI** [8] et le modèle de **TAKAGI-SUGENO** [9]. Pour faciliter l'interprétation, on peut considérer l'antécédent comme une description linguistique qui indique les conditions de validité du phénomène représenté. Pour sa part, le conséquent (conclusion) représente le comportement associé aux conditions de validité décrites par l'antécédent.

Exemple (1.6) : Prenons par exemple la règle suivante :

**Si** concentration de polluant est élevée **Alors** temps de dégradation est long

Les règles floues établissent des relations logiques entre les variables du système en associant valeurs qualitatives d'une variable (la concentration de polluant est élevée) avec celles d'une autre variable (le temps de dégradation est long). Les valeurs qualitatives ont typiquement une interprétation linguistique, elles sont nommées termes linguistiques (étiquettes). La signification des termes linguistiques par rapport aux variables d'entrée/sortie numériques (concentration de polluant, temps de dégradation) est définie par des ensembles flous appropriés. Dans ce sens, les ensembles flous, ou plus précisément leurs fonctions d'appartenance, fournissent une interface entre les variables numériques d'entrée/sortie et les valeurs linguistiques qualitatives dans les règles. Selon la structure particulière de la proposition conséquente, on peut distinguer trois types de modèles flous basés sur des règles [4]:

### I.6.1. Modèle flou mamdani:

Pour ce modèle [8] [10] l'antécédent et le conséquent sont des propositions floues qui utilisent des variables linguistiques, d'où l'appellation de modèle flou linguistique. Pour un système SISO<sup>1</sup> la forme générale des règles de Mamdani est :

**Si**  $x$  est  $A_i$  **Alors**  $y$  est  $B_i$

- $x$  est l'entrée du système flou (variable antécédente).
- $y$  la sortie (variable de conséquence).

La majorité des systèmes sont cependant décrits par plusieurs variables (MISO<sup>2</sup> ou MIMO<sup>3</sup>). Dans ce cas, les propositions antécédentes des règles sont une combinaison logique à l'aide des opérateurs flous.

### I.6.2. Modèle flou relationnel:

Ce modèle [11] peut être considéré comme une généralisation du modèle linguistique dans lequel il est possible d'associer une proposition « antécédent » spécifique avec plusieurs propositions « conséquents » différentes via une relation floue. Cette relation floue représente des associations entre les ensembles flous individuels définis dans les domaines d'entrée/sortie du modèle.

Exemple (1.7) : Soit la fonction  $y=f(x)$  décrite par la relation floue suivante :

$$R = \begin{pmatrix} 0.5 & 0 \\ 0.45 & 0 \\ 0.8 & 0.1 \end{pmatrix}$$

Les éléments  $r_{ij}$  décrivent les associations entre les ensembles flous  $A_i$ ,  $i=1,2,3$  définis sur  $x$  et les ensembles flous  $B_j$ ,  $j=1,2$  définis sur  $y$ , cette relation peut être interprétée par :

Si  $x$  est  $A_1$  alors  $y$  est  $0.5B_1$ ,  $y$  est  $0B_2$

Si  $x$  est  $A_2$  alors  $y$  est  $0.45B_1$ ,  $y$  est  $0B_2$

Si  $x$  est  $A_3$  alors  $y$  est  $0.8B_1$ ,  $y$  est  $0.1B_2$

Un modèle linguistique approximatif peut être calculé par un modèle relationnel et cela en considérant seulement les conséquences possédant le poids le plus élevé. En supposant que les ensembles flous antécédents forment une partition, le modèle relationnel précédent peut être remplacé par le modèle suivant :

$$\text{Si } x \text{ est } A_1 \text{ alors } y = \frac{0.5b_1}{0.5}.$$

$$\text{Si } x \text{ est } A_1 \text{ alors } y = \frac{0.45b_1}{0.45} .$$

$$\text{Si } x \text{ est } A_1 \text{ alors } y = \frac{0.8b_1 + 0.1b_2}{0.8 + 0.1} .$$

### I.6.3. Modèle flou takagi-sugeno (TS):

La partie conséquent du modèle TS utilise des variables numériques plutôt que des variables linguistiques, sous la forme d'une constante, d'un polynôme ou de manière plus générale d'une fonction ou d'une équation différentielle dépendant des variables associées à la proposition antécédente [9]. Les conséquences des règles sont des fonctions « strictes » des entrées du système flou. Elles s'écrivent, dans le cas général sous la forme:

$$R_i : \text{Si } x \text{ est } A_i \text{ alors } y_i = f_i(x)$$

La sortie de chaque règle est une combinaison linéaire des variables d'entrée plus un terme constant, et la sortie finale est la moyenne pondérée de la sortie de chaque règle.

Le système de l'électrovanne étudié est complexe et non-linéaire, il sera modélisé par un modèle TS. Nous développerons encore plus ce modèle aux chapitres II et IV.

## I.7. Diagnostic industriel:

### I.7.1. Définitions:

Le diagnostic industriel, a pour objet de trouver la cause d'une défaillance. Nous adopterons la définition qui a été retenue par les instances internationales de normalisation (AFNOR, CEI) : "le diagnostic est l'identification de la cause probable de la (ou des) défaillance(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test". Cette définition très courte et concise résume les deux tâches essentielles du diagnostic [12] :

- Reconnaître les symptômes de la défaillance.
- Identifier la cause de la défaillance à l'aide d'un raisonnement logique fondé sur un ensemble d'observations.

La sélection de la méthode de diagnostic la plus appropriée à un système industriel donné ne peut se faire qu'après un recensement des besoins et des connaissances disponibles. L'inventaire des éléments à étudier est le suivant :

- ✓ nature des causes de défaillances à localiser ;
- ✓ connaissance des signatures associées aux défaillances induites par les causes,
- ✓ maîtrise des moyens de mesure des symptômes,
- ✓ maîtrise des moyens de traitement des symptômes,
- ✓ connaissance des mécanismes physiques entre les causes et les effets,
- ✓ inventaire du retour d'expérience,
- ✓ recensement des expertises disponibles,
- ✓ définition du niveau de confiance dans le diagnostic,
- ✓ identification des utilisateurs finaux du diagnostic.

La procédure de diagnostic de défaillances d'un processus industriel tourne autour des étapes suivantes [12] :

- ✓ l'extraction des informations à partir de moyens de mesures appropriées ou d'observations réalisées lors des rondes par le personnel de surveillance,
- ✓ l'élaboration des caractéristiques et signatures associées à des symptômes,
- ✓ la détection d'un dysfonctionnement,
- ✓ la mise en œuvre d'une méthode de diagnostic de la défaillance ou de la dégradation à partir de l'utilisation des connaissances sur les relations de cause à effet,
- ✓ la prise de décision (arrêt de l'installation ou reconfiguration).

Le diagnostic peut s'effectuer dans deux contextes différents: le diagnostic hors ligne (off line) utilisé pour les traitements curatifs de panne et le diagnostic en ligne ou encore en temps réel (on line) utilisé en vue d'une tâche de supervision pour détecter les défauts au moment où ils se produisent. Nous précisons ici le [12] [13] vocabulaire relatif au diagnostic dans le domaine technique (le diagnostic industriel) :

- **Système "dispositif"**: un ensemble déterminé d'éléments discrets (ou composants) interconnectés ou en interaction.
- **Processus**: ensemble de phénomènes organisés dans le temps rapportés à un même système physique.

- **Anomalie:** particularité non conforme à la loi naturelle ou à la logique. Plus précisément: particularité non conforme à une référence comportementale ou fonctionnelle.

Exemple (1.8) : Les défauts, les défaillances, ou les pannes sont des anomalies.

- **Observation:** c'est une information obtenue sur le dispositif réel. Cette information peut être obtenue soit à une entrée, soit à une sortie du dispositif ou encore entre deux composants de celui-ci.
- **Symptôme:** caractère distinctif d'un état fonctionnel anormal (i.e. Variation anormale d'une quantité observable).
- **Résidu** : souvent, lorsque le modèle comportemental de référence est analytique, les signaux porteurs de signes ou de symptômes sont appelés résidus parce qu'ils résultent d'une comparaison entre un comportement réel et un comportement de référence.
- **Défaillance:** L'altération ou la cessation de l'aptitude d'un système à accomplir sa ou ses fonctions requise(s) avec les performances définies dans les spécifications techniques". Elle définit une anomalie fonctionnelle au sein du système. La défaillance peut se produire à différents niveaux: capteurs, actionneurs, composants du procédé, contrôle dans le cas d'une boucle.
- **Panne\_:** C'est l'inaptitude d'un dispositif à accomplir une fonction requise. Il est clair que dès l'apparition d'une défaillance, caractérisée par la cessation du dispositif à accomplir sa fonction, on déclarera le dispositif en panne. Par conséquent une panne résulte toujours d'une défaillance mais la présence d'une défaillance n'entraîne pas obligatoirement la présence d'une panne.
- **Défaut** : dysfonctionnement tolérable qui ne cause pas un arrêt complet du système dû à une imperfection physique liée à la conception ou à la mise en œuvre du dispositif, il peut donner lieu à une défaillance.

Les défauts selon leurs sources peuvent être classifiés comme suit :

- Défaut des capteurs,
- Défaut des actionneurs,

- Défaut du système lui-même (fuite, rupture d'organe, ..),
- Défaut de l'unité de traitement ou de commande,
- Défaut dû à l'opérateur humain.

### I.7.2. Classifications des méthodes de diagnostic:

Les premières méthodes de diagnostic ont été basées sur la redondance matérielle, parce qu'elle est très répandue dans les domaines où la sûreté de fonctionnement est cruciale comme dans l'aéronautique ou le nucléaire. Dans la littérature on distingue plusieurs classifications des méthodes de diagnostic [12] [13] :

- 1- Selon le type de données utilisées : approches numériques et symboliques.
- 2- Selon le comportement du modèle du système : méthodes internes et méthodes externes.
- 3- Selon le type de raisonnement utilisé : méthodes inductives et déductives.
- 4- Selon la source des connaissances utilisées : méthodes heuristiques et analytiques et les méthodes hybrides.

La taxinomie des méthodes de diagnostic permet une première classification en plusieurs grandes familles : les méthodes internes et externes et les méthodes inductives et déductives. Toutes ces méthodes sont résumées à la figure suivante :

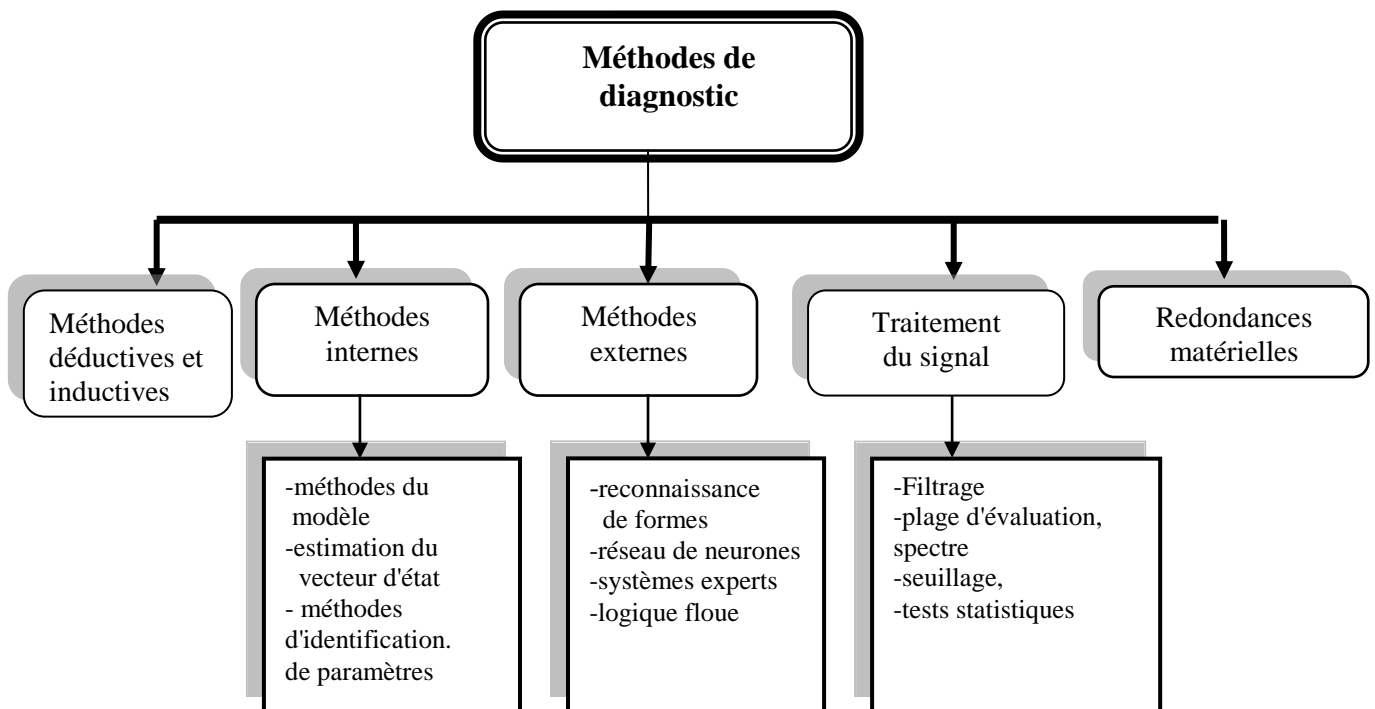



Fig. 1.11 : Méthodes de diagnostic.

### I.7.2.1. Méthode de diagnostic par redondance matérielle:

L'idée principale est de multiplier les chaînes de mesure, pour une acquisition fiable d'une grandeur physique (Fig.1.12). Les mesures sont comparées entre elles, si une mesure ne concorde pas avec les autres mesures, un vote logique permet d'isoler le capteur défaillant. Le rôle du voteur est de déterminer le capteur défaillant par l'analyse de la dispersion des trois mesures  $r_1$ ,  $r_2$  et  $r_3$ . L'approche redondance matérielle est très efficace bien qu'elle ne couvre pas les pannes de mode commun :

- panne d'alimentation électrique,
- panne de masse, etc.

Le coût et l'encombrement ainsi qu'un champ d'application strictement limité aux pannes de capteurs constituent les inconvénients majeurs de cette méthode.



**Fig. 1.12 :** La redondance matérielle.

### I.7.2.2. Méthodes internes et méthodes externes:

#### A) Les méthodes internes: [12]


Ces méthodes sont basées sur des modèles physiques ou mathématiques validés par les techniques d'identification de paramètres. Le diagnostic de défaillance est possible en suivant en temps réel l'évolution des paramètres physiques ou bien en utilisant l'inversion de modèles de type « boîte noire ». On distingue trois grandes familles :

- méthode du modèle;
- méthodes d'identification de paramètres;
- méthode d'estimation du vecteur d'état.

#### a) la méthode du modèle :

Le système à diagnostiquer est doublé par un modèle qui fonctionne en parallèle. Les entrées du système sont répercutées sur les entrées du modèle.

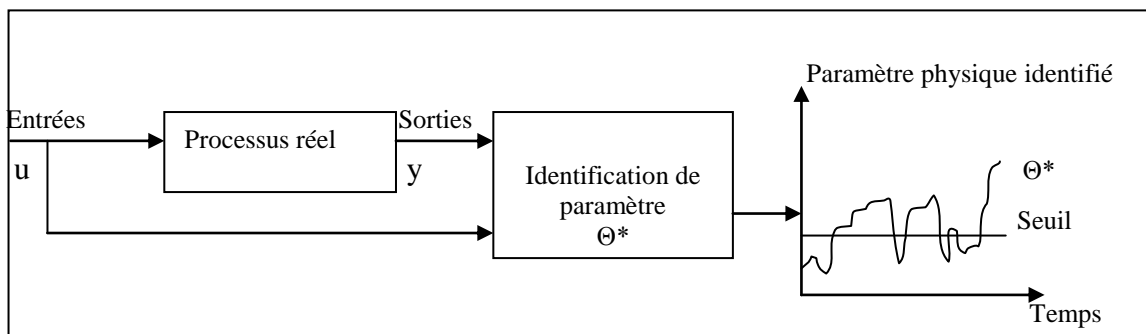
A partir des sorties déduites du modèle et des mesures directement observées sur le système réel, un résidu qui exprime les écarts de comportement, est généré. La présence d'un écart signifie l'apparition d'une anomalie.



**Fig. 1.13 :** Méthode du modèle.

b) les méthodes d'identification de paramètres :

Elle s'applique au cas où l'on souhaiterait suivre l'évolution de certains paramètres critiques pour le fonctionnement du système et qui ne sont pas directement mesurables. Le principe général de cette méthode est d'estimer les paramètres internes physiques représentés par un vecteur paramètre  $\Theta^*$  du modèle à partir de la connaissance des signaux d'entrées  $u$  et de sortie  $y$  mesurés sur le système par des méthodes appropriées. Le diagnostic se fait en suivant l'évolution au cours du temps du paramètre physique concerné et de le comparer à un seuil prédéterminé.

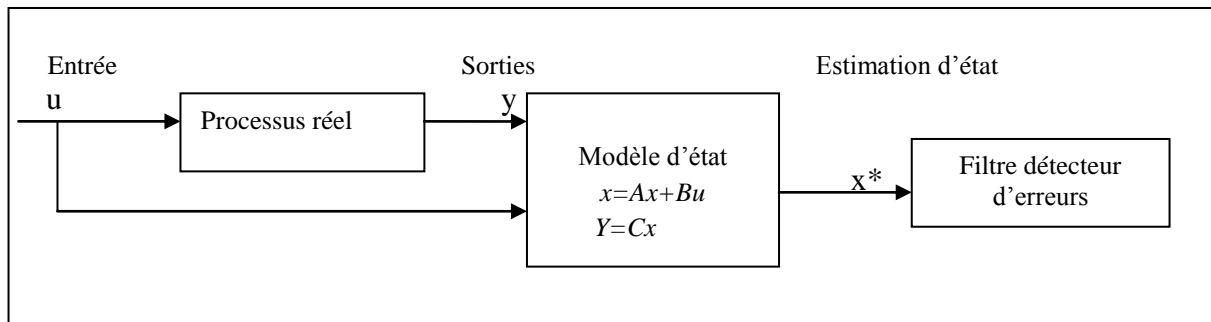


**Fig. 1.14 :** Méthode d'identification de paramètres.

c) la méthode d'estimation du vecteur d'état :

Cette méthode est utilisée lorsque les anomalies se manifestent directement sur les variables d'état. Son principe consiste à estimer par des techniques appropriées (observateurs d'état)

toutes les composantes du vecteur d'état  $\mathbf{x}$  à partir de la connaissance du vecteur de mesure  $\mathbf{y}$  et du vecteur d'entrée  $\mathbf{u}$ . L'analyse du comportement des estimations des états qui ont un sens physique permet la réalisation du diagnostic.



**Fig. 1.15 :** Méthode d'estimation du vecteur d'état.

Les éléments des matrices  $A$ ,  $B$ ,  $C$ , représentent les paramètres physiques du processus et sont supposés connus.

### **B) Les méthodes externes:** [12]

Ces méthodes supposent qu'aucun modèle n'est disponible pour décrire les relations de cause à effet. La seule connaissance repose sur l'expertise humaine confortée par un solide retour d'expérience. Dans cette catégorie on retrouve toutes les méthodes basées sur l'intelligence artificielle et les approches probabilistes. La résolution de diagnostics des défaillances par les méthodes de l'intelligence artificielle est due principalement aux avantages suivants :

- La non nécessité à la modélisation.
- L'insertion de connaissances d'experts sous forme linguistique : soit pour la détection ou la localisation des défauts.
- La simplicité de la mise en œuvre, une fois que les règles d'expert sont préparées.
- La robustesse face aux perturbations.

#### a) la reconnaissance de formes :

L'interprétation des signatures des défaillances fait appel aux techniques de reconnaissance des formes, ou :

- les formes, sont les vecteurs des observations, les classes, les modes de fonctionnement,
- et la discrimination, le choix du mode de fonctionnement.

La conception d'un tel système de diagnostic se déroule en trois phases :

1) Une phase d'analyse : On étudie le processus à diagnostiquer pour définir le vecteur forme (paramètres à observer) et caractériser les différentes classes. A l'issue de cette phase, l'espace de représentation de dimension  $\mathbf{d}$  est connu, toute nouvelle observation  $\mathbf{y}$  sera représentée par un point, on dispose aussi de  $\mathbf{M}$  classes notées  $w_1, w_2, \dots, w_m$ , qui serviront de base au système de décision.

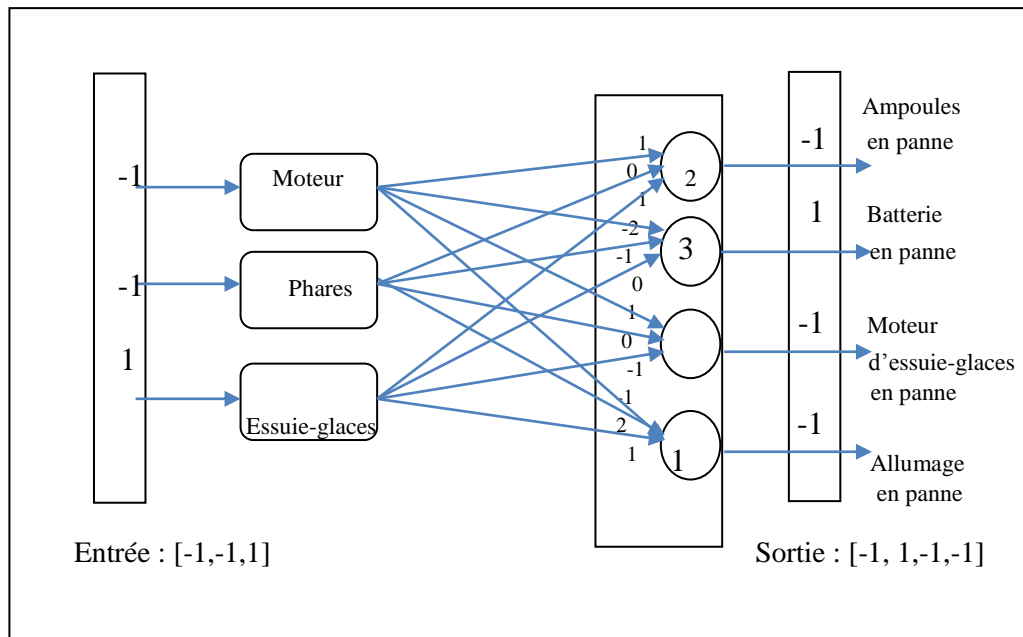
2) Une phase de choix d'un système de décision : On élabore un système de décision qui décidera de l'appartenance ou non d'une nouvelle observation  $x$  à une des classes. Dans ce système l'observation peut être soit attachée à une des classes connues, soit rejetée de toutes ces classes et faire l'objet d'une nouvelle classe.

3) Une phase d'exploitation : Dans cette phase, on fait l'observation, on calcule la forme associée dans l'espace de représentation et on procède à sa classification.

b) les réseaux de neurones artificiels:

Les réseaux de neurones sont parmi les techniques heuristiques des plus utilisées dans les applications industrielles. Ils ont la capacité de classer des signatures même si les formes présentées sont entachées de bruits ou ont des informations manquantes. Faire un diagnostic consiste à déterminer à quelle classe appartient une situation particulière.

Exemple (1.9) :



c) systèmes experts :

Un système expert (SE) est un système informatique destiné à résoudre un problème précis à partir d'une analyse, d'une représentation des connaissances et du raisonnement d'un (ou plusieurs) spécialiste(s) de ce problème. L'un des principaux modules d'un SE est la base de connaissances formée de:

- La base de règles : qui contient les règles permettant l'association des faits entre eux.
- La base des faits : elle contient les éléments observables collectés sur le système à diagnostiquer, ou des faits déduits par le système expert à partir des éléments observés.

### I.7.2.3. Les méthodes inductives et les méthodes déductives: [12]

#### A) Les méthodes inductives:

Ces méthodes correspondent à une approche montante où l'on identifie toutes les combinaisons d'événements élémentaires possibles qui entraînent la réalisation d'un événement unique indésirable. En d'autres termes il faut interpréter les symptômes ainsi que leurs combinaisons possibles afin de trouver le défaut.

- ✓ Arbre de défaillances : L'arbre de défaillance a deux objectifs: déduire les causes d'un événement unique indésirable et représenter graphiquement l'enchaînement de ses causes. Il est constitué de niveaux successifs tels que chaque événement à un niveau donné est généré à partir de combinaisons logiques «ET» et «OU» d'événements du niveau inférieur. Le chemin critique est le scénario d'événements élémentaires, indépendants entre eux, qui entraînent l'apparition de l'événement redouté. Les Arbres de défaillances peuvent être transformés en

Arbres de tests par l'ajout de nœuds correspondants aux tests qui doivent être réalisés pour augmenter la connaissance et permettre de déterminer la cause de la défaillance parmi les causes possibles [13].

### **B) Les méthodes déductives:**

Pour ces méthodes, la démarche est bien sûr inversée puisque l'on part de l'événement indésirable et l'on recherche ensuite par une approche descendante toutes les causes possibles. Une vérification des effets trouvés par rapport aux effets possibles permet de confirmer ou d'infirmer l'existence du défaut. La prise de décision par les spécialistes des matériels qui possèdent une maîtrise des phénomènes physiques, s'exerce à chaque étape d'une procédure de diagnostic industriel. Lors de la détection de dysfonctionnement, il faut fixer des seuils de pré-alarme et alarme sur la valeur de l'écart mesuré entre la signature nominale et celle mesurée. Pour déterminer ces seuils, il est alors nécessaire de définir des tests de décisions.

- ✓ AMDE et AMDEC (Analyse des Modes de Défaillances, de leurs Effets et de leur Criticité) : L'analyse AMDE est une technique par laquelle les effets des causes de défaillances sont systématiquement identifiés. L'AMDEC utilise une démarche similaire à celle de l'AMDE en indiquant de plus, la criticité des effets de la défaillance.

---

<sup>1</sup> Système SISO = Système à une entrée et une sortie (Simple-Input Simple-Output)

<sup>2</sup> Système MISO = Système à plusieurs entrées et une sortie (Multiple-Input Simple-Output)

<sup>3</sup> Système MIMO = Système à plusieurs entrées et plusieurs sorties (Multiple-Input Multiple-Output)

II.1. Introduction.

II.2. Description de l'électrovanne.

II.3. Les défauts.

II.3.1. Description des défauts.

II.3.2. Modes de défaillances.

II.3.2.1. Défaut brusque.

II.3.2.2. Défaut progressif.

II.4. Modèle simulink de l'électrovanne.

II.5. Modélisation flou de type Takagi-Sugeno.

II.6. La méthode FDI.

II.6.1. Introduction.

II.6.2. Génération de résidus.

II.6.3. Principe de détection.

II.6.4. Localisation.

## II.1. Introduction:

Un benchmark est indispensable pour comparer, opposer et évaluer un grand nombre de méthodes FDI (Fault Diagnosis and Isolation : Diagnostic de Défaits et Isolation), en termes d'évaluation de critères de performances standards ; et répondre aussi à des besoins industriels typiques [14]. Un tel benchmark a été développé dans le cadre du projet Européen DAMADICS (Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems). Il a servi au développement de méthodes FDI sur trois actionnaires (électrovannes de régulation) dans une usine de fabrication de sucre en Pologne [15]. La construction d'un benchmark pour l'étude de ce type d'actionnaire est motivé par le fait que : ce dernier étant installé dans un environnement sévère (température élevée, humidité, pollution, solvants chimiques, etc.), il est alors exposé au risque d'un dysfonctionnement. La détection précoce de faibles défauts ou les dérives lentes de ses caractéristiques augmente la durée de vie de l'actionnaire. Les défauts de l'électrovanne qui perturbent le processus de production et son arrêt constituent le principale souci économique, ils peuvent engendrer parfois des problèmes de pollution voir de sécurité du personnel. L'état de fonctionnement de l'actionnaire influence directement la qualité du produit final (le sucre). Une étude utilisant le benchmark a deux objectifs : (i) la modélisation, (ii) l'exploitation de données réelles et l'émulation de défauts. Ceci nous offre la possibilité de développer des méthodes FDI de plus en plus efficaces, pour éviter les problèmes qu'ont viennent de citer. Le benchmark utilise un ensemble complet de scénarios de défauts réels et simulés, servant de plateforme commune pour le test et la comparaison de nouvelles méthodes de diagnostic de défauts.

La production de sucre nécessite plusieurs procédés. L'installation objet de cette étude possède [15] un processus d'évaporation à 7 évaporateurs regroupés en 5 sections (sections I, IV, V composés d'un évaporateur chacune et les sections II et III se composent de deux évaporateurs chacune). Ce processus d'évaporation utilise 3 électrovannes de régulation opérant dans des conditions et environnements différents.

## II.2. Description de l'électrovanne:

Les trois électrovannes ayant servi de modèle pour la construction du benchmark ont la même structure générale. Ces 3 actionnaires sont : [16] [17]

### ✚ Actionnaire (LC51\_03)

**Fonction** : Sert pour la régulation du flux de jus de betterave dilué entrant dans l'évaporateur.

**Emplacement** : Située au niveau de la boucle de contrôle dans la 1<sup>er</sup> section de la station d'évaporation.

### ✚ Actionnaire (FC57\_03)

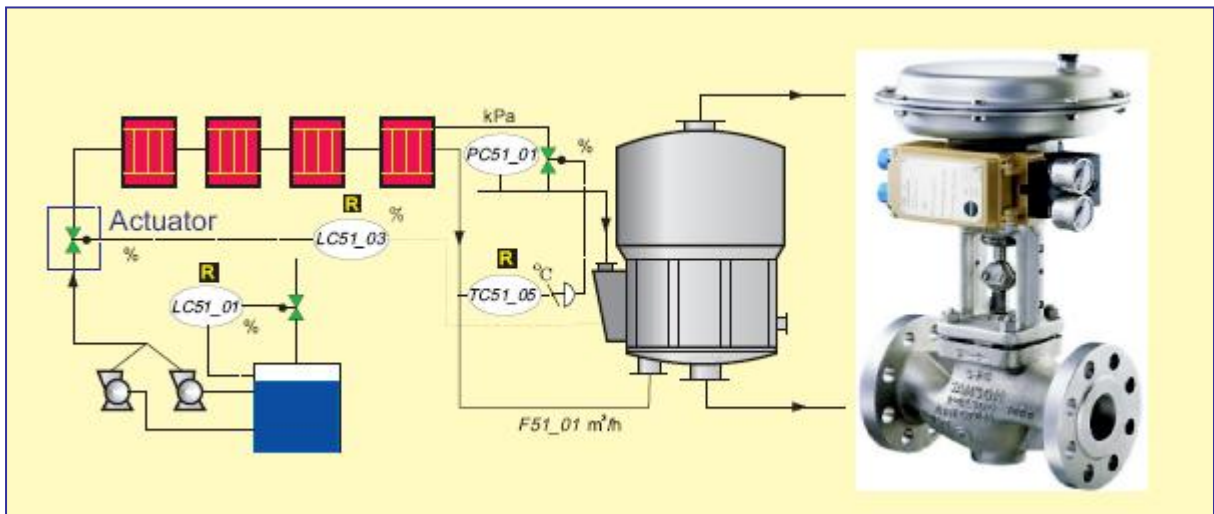
**Fonction** : Sert pour la régulation du flux de jus de betterave concentré sortant de l'évaporateur.

**Emplacement** : 5<sup>eme</sup> section de la station d'évaporation.

### ✚ Actionnaire (LC74\_20)

**Fonction**: Sert pour la régulation du niveau d'eau dans les chaudières de production de vapeur.

**Emplacement** : 4<sup>eme</sup> section de la station d'évaporation.



**Fig. 2.1:** Régulation de flux de jus de betterave dans l'usine de sucre.

Ce type d'électrovanne appartient à la classe des actionnaires électro-pneumatiques dits « intelligents » très répandus en milieu industriel. Elle est constituée par l'assemblage de trois éléments (Figure 2-2) : [16]

- ✚ le corps de la vanne (V),
- ✚ le servomoteur pneumatique (S),
- ✚ et le positionneur (P).




Fig. 2.2 : Structure de l'électrovanne de régulation.

➤ Eléments auxiliaires :

PT - transmetteur de pression.

FT - transmetteur du débit.

TT - transmetteur de température.

ZT - transmetteur de position.

PSP - alimentation d'air du positionneur.

La conduite sur laquelle est montée l'électrovanne possède un circuit parallèle comme indiqué sur l'image de la figure 2-2. Ce circuit parallèle est prévu pour permettre le remplacement de l'actionnaire sans interruption de l'écoulement du liquide. Quand on veut remplacer l'électrovanne pour cause de maintenance, on ferme les deux vannes V1, V2 et on ouvre la vanne V3.

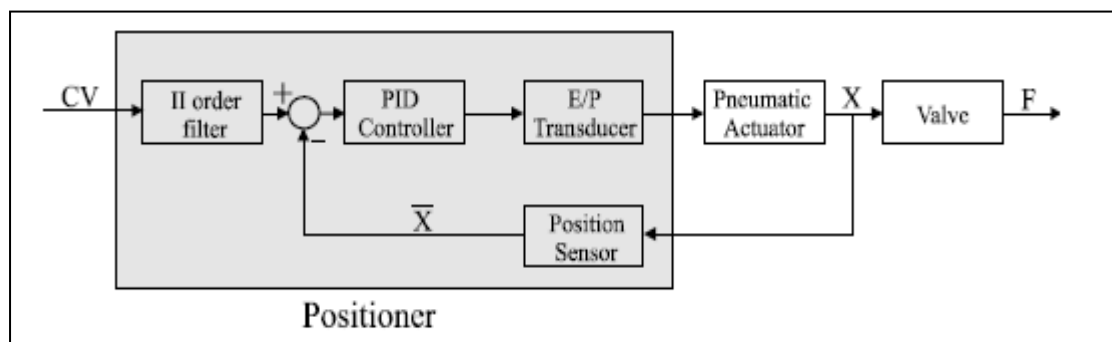
Le corps de la vanne est l'élément qui permet le réglage du débit du liquide circulant dans les conduites de l'installation. Le servomoteur assure la conversion du signal de commande en mouvement de la vanne. L'élément electro-pneumatique (E/P) du positionneur converti un signal électrique en une pression d'un fluide moteur agissant sur le diaphragme (membrane) du servomoteur, qui à son tour actionne la tige de clapet de la vanne dans un mouvement linéaire. Un ressort antagoniste au diaphragme, s'oppose au déplacement dans une direction. Lorsque la pression du fluide moteur diminue, il rappelle la tige vers le haut. Ce ressort assure aussi la position de sécurité de la vanne par manque de fluide moteur : la vanne reste ouverte [14] [18].

L'effort développé par le servomoteur à deux buts :

- Lutter contre la pression agissant sur le clapet;
- Assurer l'étanchéité de la vanne;

En général, le fluide moteur agissant sur le diaphragme est de l'air et la pression de commande varie de 0,2 bar à 1 bar.

Le rôle du positionneur est de garantir la position correcte de l'obturateur par rapport au siège de la vanne pour un signal de commande donné.



**Fig. 2.3** : Schéma du contrôleur du positionneur.

Le positionneur de la figure 2.3 détermine le flux de l'air entrant dans la chambre du servomoteur. Le positionneur est l'élément qui contrôle la position X de la tige. Il reçoit un signal référence de contrôle (CV) délivré par l'automate contrôlant le process, qui passe à travers un filtre de second ordre. Ce filtrage élimine le bruit et les changements brusques de

CV, avant l'action du contrôleur PID qui stabilise la tige dans une position correspondante au signal de référence. Le positionneur se compose d'un capteur de position et d'un transducteur électro-pneumatique (E/P). Le premier détermine la position actuelle de la tige, par conséquent l'erreur entre la position réelle et celle de la consigne peut être obtenue. Le transducteur E/P reçoit un signal CVI (fig 2.2) du contrôleur PID qu'il transforme en un signal qui injecte ou aspire de l'air de la chambre du servomoteur. Ce transducteur est connecté à un circuit pneumatique et à l'atmosphère. Si le contrôleur indique que la tige doit descendre, alors la chambre est connectée au circuit pneumatique. Si par contre la tige doit remonter, la connection est établie avec l'atmosphère, d'où la purge de la chambre [18].

➤ Entrées/sorties du modèle boîte noire:

Le modèle boîte noire de l'électrovanne est décrit par 5 variables physiques (P1, P2, T1, X, F) et une variable de contrôle CV [14]. Toutes ces variables sont complètement décrites par le benchmark :

**CV** - Un signal externe de contrôle produit par un automate; au cours de la simulation, il est exprimé en pourcent

**P1** - Pression en entrée de la vanne

**P2** - Pression en sortie de la vanne

**T1** - Température du liquide en entrée de la vanne

Ces quatre grandeurs (CV, P1, P2, T1) seront les variables d'entrées du modèle de l'électrovanne.

**X** - Déplacement de la tige

**F** - Flux du liquide

Ces deux grandeurs (X, F) seront les variables de sortie du modèle.

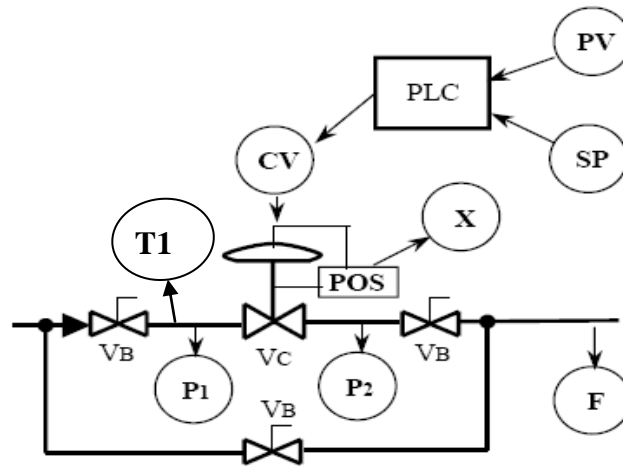


Fig. 2.4 : Variables d'entrées/sorties de l'actionnaire [19].

**PV** : Variable du process, le niveau d'un liquide par exemple

**SP** : Consigne fixée par l'opérateur,

**VC** : Vanne de contrôle,

**VB** : Vanne manuelle.

Le schéma général du bloc du modèle physique de l'électrovanne est donné par la figure 2.5



Fig. 2.5 : Modèle entrée-sortie de l'électrovanne.

## II.3. Les défauts:

### II.3.1. Description des défauts:

Etant donné le nombre illimité de scénarios possibles de défauts, seuls les défauts les plus plausibles ont été retenus pour la construction du benchmark. C'est un ensemble de 19 défauts [20] répartis en 4 groupes: [21] [22]

- défauts du corps de la vanne {f1..f7}
- défauts du servomoteur {f8..f11}
- défauts du positionneur {f12..f14}
- défauts externes/généraux {f15..f19}

Nous proposons la traduction de l'anglais vers le français de la description des défauts. Le texte intégral original est proposé en annexe A.

**a) défauts du corps de la vanne:**

- f1 – blocage du mouvement du piston du servomoteur
- f2 – sédimentation du siège de la vanne
- f3 – érosion du siège de la vanne
- f4 – augmentation des frottements.
- f5 - fuite externe
- f6 - fuite interne.
- f7 - évaporation ou bien débit critique.

**b) défauts du servomoteur:**

- f8 – torsion de la tige du piston du servomoteur
- f9 – problème d'étanchéité ou de serrage
- f10 - perforation du diaphragme (membrane)
- f11 – défaut du ressort antagoniste.

**c) défauts du positionneur:**

- f12 – défaut du transducteur électro-pneumatique (E/P)
- f13 – défaut du capteur de déplacement de la tige (ZT)
- f14 – défaut du capteur de pression (PT)
- f15 - défaut dans la contre-réaction du positionneur causé par le ressort.

**d) défauts général /externes:**

- f16 – chute de la pression d'alimentation en air du positionneur
- f17 – changement inattendu de la pression à travers la vanne
- f18 - vanne de dérivation totalement ou partiellement ouverte
- f19 – défaut du capteur de débit (FT)

**II.3.2. Modes de défaillances:**

Les défauts considérés peuvent donner lieu à des défaillances. Celles-ci se manifestent selon deux modes [14] [20]: brusque ou progressif. Pour le mode brusque on peut citer par exemple le blocage de l'obturateur par un objet tel un caillou. Dans ce cas il y a un changement rapide des signaux de sorties X et F. Par contre pour le mode progressif la variation des signaux en sortie est difficilement décelable. C'est le cas par exemple d'un dépôt de sédiments dans le siège de la vanne, F et X variant lentement.

### II.3.2.1. Défaut brusque:

L'effet de ce défaut se développe rapidement, presque instantanément. Pour ce type de défaut il a été défini 3 niveaux d'intensités normalisés pour le benchmark.

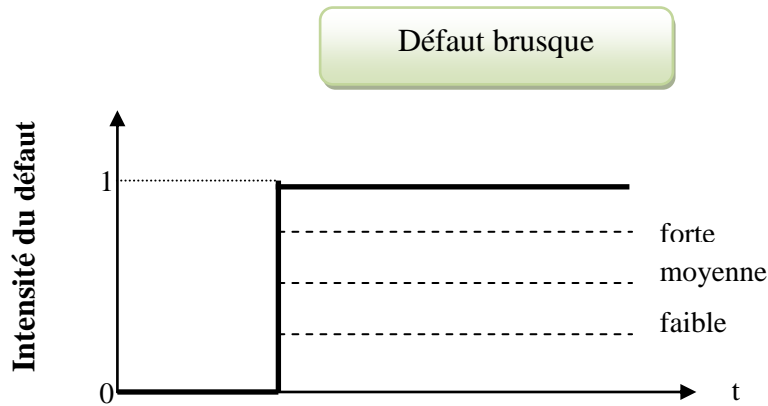


Fig. 2.6 : Représentation des défauts brusques.

### II.3.2.2. Défaut progressif:

L'effet de ce défaut se développe au cours du temps de façon progressive. Comme pour le défaut brusque, il a été défini 3 durées de développement de ce défaut pour le benchmark.

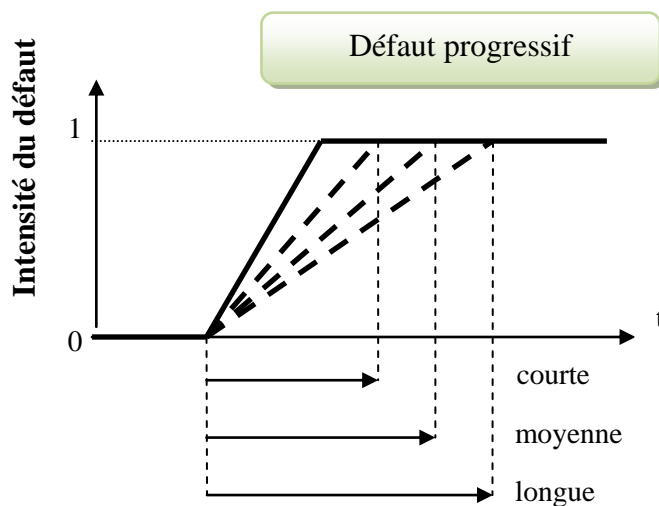


Fig. 2.7 : Représentation des défauts progressifs.

#### II.4. Modèle simulink de l'électrovanne:

Un modèle SIMULINK a été développé dans le cadre du benchmark de l'électrovanne [15]. Ce modèle est un ensemble de plusieurs blocks SIMULINK formant une librairie [23], cette librairie a été conçue autour d'un modèle complexe de l'actionnaire.

Les blocks de cette librairie sont regroupés en trois catégories :

- blocks de l'actionnaire,
- générateurs de données
- blocks utilitaires.

On propose quelques principaux blocs à la figure 2.8 :




Fig. 2.8: Blocks Simulink de DABLIB.

Le composant Act simule entièrement l'électrovanne, il sera intégré dans notre schéma de diagnostic. Le bloc DGEN est un composant qui renferme le module ACT et simule les signaux d'entrées CV, P1, P2 et T1, ainsi que le vecteur des défauts  $f_i$ . Il délivre en sortie des mesures de simulation pouvant servir à la validation de certains algorithmes de diagnostic lors des premières phases de développement. Le module ExtAct est identique au composant Act, il a en plus trois variables de sortie ( $P_{Z'}$ ,  $CVI'$  et  $P_{S'}$ ) [23]. Ce dernier bloc est utilisé dans des études

avancées de diagnostic, il peut servir pour l'évaluation et le test de qualité des algorithmes [14] de type FDI.

Pour notre simulation nous utilisons le bloc Act (figure 2.8). Il accepte comme entrée les variables suivantes :

- **CV** : variable de contrôle,
- **P1** et **P2** : pressions en entrée et en sortie de la vanne,
- **T1** : température du liquide à l'entrée de la vanne,
- **f** : vecteur des défauts {f1 à f19}

La simulation s'exécute selon le schéma suivant :




Fig. 2.9 : Principe de simulation.

En sortie du block Act, seules les variables ( $F'$  et  $X'$ ) correspondantes aux signaux réelles de mesure délivrés par l'actionnaire seront prises en compte. Le marquage par une apostrophe de F et X signifie que le modèle produit des sorties bruitées, exactement comme les mesures réelles délivrées par les transmetteurs FT et ZT. L'observation des deux résidus (resX et resF) indique l'existence ou non d'un défaut. Ce schéma servira pour notre application en chapitre

III. Il sera complété par un module d'évaluation des résidus et de décision flou.

Le Simulink offre la possibilité de superposer un bruit blanc aux signaux internes du block Act [23].

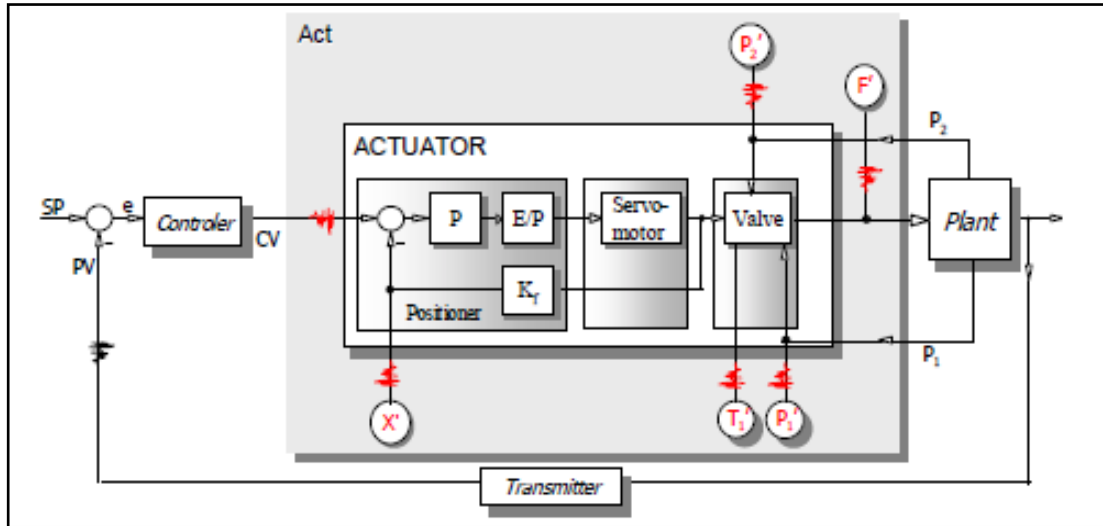


Fig. 2.10 : Simulation d'un bruit blanc

Le bloc FGEN permet de fixer les caractéristiques du défaut simulé à l'aide de 5 paramètres. On peut simuler l'intensité, la durée ainsi que le sens d'évolution du défaut. On illustre ces trois caractéristiques [23] par la figure suivante :

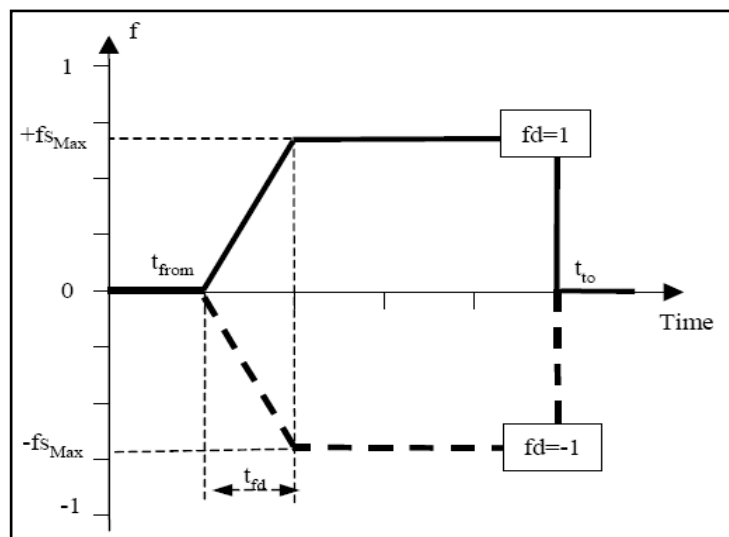


Fig. 2.11 : Caractéristiques du bloc FGEN.

❖ Paramètres du défaut simulé :

$f_s$  : intensité,

$f_d$  : direction,


$t_{fd}$  : temps de développement,

$t_{from}$  : instant de début de simulation,

$t_{t0}$  : instant de fin de simulation.

On simule la direction du défaut lorsque celui-ci agit sur la caractéristique de certains composants de l'actionnaire (par exemple le transducteur electro-pneumatique) en la déplaçant dans un sens ou dans l'autre. La plupart des défauts considérés ont une seule direction positive.

Le bloc FSEL de sélection de défauts permet de choisir un défaut parmi 19 défauts, la sélection de "NO FAULT" est également possible ; le block FGEN assurant le paramétrage du défaut sélectionné [23].



**Fig. 2.12 :** Le bloc FSEL.

## II.5. Modélisation floue de type Takagi-Sugeno:

L'objectif de la modélisation consiste à trouver un compromis entre la complexité du modèle et sa performance numérique au niveau de la représentation du système dynamique. La modélisation floue d'un système consiste le plus souvent à coder les connaissances de l'expert exprimées dans un langage naturel en une collection de règles **SI...ALORS** ; on obtient ainsi une structure de modèle. Les paramètres de cette structure sont déterminés en utilisant les données entrées-sorties de ce système. Les modèles flous sont construits à partir de ces données par l'approximation d'une fonction. On suppose que ce système est décrit par une fonction **F**:

$y = \mathbf{F}(x)$ . Il s'agit maintenant d'utiliser les données pour construire une fonction  $y = f(x)$  approximant **F**(x). Cette fonction 'f' est une collection de règles **SI...ALORS** [3] [7].

Nous considérons une structure de modèle basé sur des règles de type TS. Le choix d'un modèle de type TS est justifié par l'excellente performance de modélisation due à la possibilité de représenter des systèmes non-linéaires par des modèles locaux linéaires [7]. C'est un modèle Entrée Multiple/ Simple Sortie (MISO) [24]. L'estimée de la sortie  $\hat{y}$  s'exprime par :

$$\hat{y}(k+1) = f(x(k)) \quad (2-1).$$

$f$  : représente la fonction non linéaire.

$x(k)$  : vecteur de régression à l'instant  $k$  contient une collection des entrées  $u$  et des sorties  $y$  précédentes du système.

La représentation de la relation (2-1) par un modèle affine de Takagi-Sugeno est donnée par :

$$R_i : \text{Si } x_1 \text{ est } A_{i1} \text{ et } \dots \text{ et } x_n \text{ est } A_{in} \text{ Alors } y_i = a_i + b_{i1} x_1 + \dots + b_{in} x_n. \quad (2-2).$$

Pour  $i = 1, 2, \dots, r$  ;

$x_j$  : les variables d'entrée ;  $j = 1, 2, \dots, n$  ;

$y_i$  : les variables de sortie locales ;

$A_{ij}$  : ensembles flous caractérisés par les fonctions d'appartenance ;

$a_i$  : paramètres à valeur réelle ;

$b_{ij}$  : paramètres à valeur réelle ;

$R_i$  : la  $i$ -ème règle du modèle;

$r$  : nombre de règles que contient la base de règles ;

$x$  : variable d'entrée (antécédent) ;

$y$  : variable de sortie (conséquent) ;

L'idée de base de la modélisation floue de type TS est de décomposer l'espace d'entrée en régions floues et d'approximer le système dans chaque région par un modèle local linéaire. Le modèle global est composé par la concaténation de ces modèles locaux. Ce type de modèle est construit à partir d'une base de règles "Si...Alors", dans laquelle la prémisse est toujours exprimée linguistiquement, le conséquent utilise des variables numériques plutôt que des variables linguistiques. Le conséquent peut s'exprimer par exemple, sous la forme d'une constante, d'un polynôme ou de manière plus générale d'une fonction ou d'une équation différentielle dépendant des variables associées à l'antécédent [7] [25].

✓ **Inférence dans le modèle Takagi-Sugeno:** [9]

Dans la modélisation floue TS, l'obtention de la sortie du modèle est réalisée à partir d'une combinaison des opérations d'inférence et de défuzzification. La sortie finale se calcule comme la moyenne des sorties correspondants aux règles Ri, pondérées par le degré d'accomplissement normalisé  $\beta_i(x)$ .

$$\text{Ri : Si } x \text{ et } A_i \text{ Alors } y_i = a_i^T x + b_i, \quad i = 1, 2, \dots, r \quad (2-3).$$

$$y = \frac{\sum_{i=1}^r \beta_i(x) \cdot y_i}{\sum_{i=1}^r \beta_i(x)} = \frac{\sum_{i=1}^r \beta_i(x) (a_i^T x + b_i)}{\sum_{i=1}^r \beta_i(x)} \quad (2-4).$$

$\beta_i(x)$  : degré d'accomplissement de l'antécédent

$\lambda_i$  : degré d'accomplissement normalisé

$$\lambda_i = \frac{\beta_i(x)}{\sum_{i=1}^r \beta_i(x)} \quad (2-5).$$


Des équations (2-2) et (2-3) le modèle TS, peut être exprimé comme un modèle pseudo-linéaire, c'est-à-dire, un système linéaire avec des paramètres dépendants des entrées comme suit :

$$y = \left( \sum_{i=1}^r \lambda_i(x) a_i^T \right) x + \sum_{i=1}^r \lambda_i(x) b_i = a^T(x) x + b(x) \quad (2-6).$$

Où  $a(x)$  et  $b(x)$  sont des combinaisons linéaires convexes des paramètres des conséquents  $a_i$  et  $b_i$  telle que :

$$a(x) = \sum_{i=1}^r \lambda_i(x) a_i \quad (2-7).$$

$$b(x) = \sum_{i=1}^r \lambda_i(x) b_i \quad (2-8).$$



**Fig. 2.13 :** Approximation par un modèle Takagi-Sugeno.

Avant de pouvoir inférer la sortie, il faut calculer d'abord le degré d'accomplissement  $\beta_i(x)$  de l'antécédent. L'antécédent peut dépendre d'une ou de plusieurs variables. Dans le premier cas les règles ont une forme simple dans l'antécédent, pour cela le degré d'accomplissement est égal au degré d'appartenance de l'entrée multidimensionnelle  $x$  ;

$$\beta_i = \mu_{A_i}(x) \quad (2-9).$$

Exemple (2.1) :

**Si**  $x_1$  est  $A_{i1}$  **Alors**  $y_i = a_i + b_{i1} x_1 + \dots + b_{in} x_n$ .

Dans le deuxième cas, les variables sont liées entre elles par des opérateurs flous Et et OU, les règles ont alors une forme combinée dans l'antécédent (équation 2-2). Dans ce cas le degré d'accomplissement est calculé comme une combinaison des degrés d'appartenance des variables.

$$\beta_i = \mu_{A_{i1}}(x_1) \wedge \mu_{A_{i2}}(x_2) \wedge \dots \wedge \mu_{A_{in}}(x_n) \quad (2-10).$$

✓ **Identification:**

La modélisation floue des systèmes passe par deux étapes : le choix de la structure et l'estimation des paramètres du modèle. Un modèle flou TS peut être représenté par modèle de régression non-linéaire dynamique de type NARX. [7]:

$$y(k+1) = f(x(k)) \quad (2-11).$$

où  $f$  représente la fonction non linéaire et le vecteur de régression  $x(k)$  à l'instant  $k$ , contient une collection des entrées  $u$  et des sorties  $y$  précédentes du système. Dans le contexte des systèmes dynamiques, le modèle TS est mieux adapté pour le traitement et l'exploitation numérique des systèmes à entrées/sorties multiples. Les règles du modèle dynamique TS prennent alors la forme générale suivante :

$$R_i : \text{Si } Z(k) \text{ est } A_i \text{ Alors } y_i(k+1) = \theta_i^T W(k), \quad i=1,2,\dots,r \quad (2-12).$$

où les variables de l'antécédent  $Z(k)$  et du conséquent  $W(k)$  sont usuellement choisies à partir du vecteur de régression  $x(k)$ . Le modèle contient deux principaux jeux de paramètres, les paramètres  $\theta_i$  des conséquents et les paramètres définissant les fonctions d'appartenance pour les sous-ensembles flous  $A_i$ . Ainsi, les règles du modèle TS peuvent être écrites sous la forme suivante :

$$R_i : \text{Si } y(k) \text{ est } A_{i1} \text{ et } y(k-1) \text{ est } A_{i2} \text{ et } \dots \text{ et } y(k-n_y+1) \text{ est } A_{iny} \\ \text{et } u(k) \text{ est } B_{i1} \text{ et } u(k-1) \text{ est } B_{i2} \text{ et } \dots \text{ et } u(k-n_u+1) \text{ est } B_{imu} \quad (2-13).$$

Alors :

$$y_i(k+1) = \sum_{j=1}^{n_y} a_{ij} y(k-j+1) + \sum_{j=1}^{n_u} b_{ij} u(k-j+1) + d_i \quad (2-14).$$

Avec  $i=1,\dots,r$

La sortie globale du modèle est calculée à partir de l'expression :

$$y(k+1) = \sum_{i=1}^r \lambda_i(k) y_i(k+1) \quad (2-15).$$

$$\text{Avec : } \begin{cases} \sum_{i=1}^r \lambda_i(k) = 1. \\ \lambda_i(k) \in [0, 1] \end{cases} \quad (2-16).$$

Pour estimer le jeu de paramètres des antécédents et des conséquents on doit modéliser le système cette fois-ci non plus avec des règles mais avec des données des variables d'entrées et de sorties. Nous avons choisi le modèle NARX (Nonlinear AutoRegressive with eXogenous Input) pour établir une relation d'entrée-sortie. Ce choix est motivé par le fait que ce modèle

étant non-réursive l'estimation de ses paramètres devient facile. Il a été prouvé que les système non linéaire, discret à temps-invariant peuvent toujours être représentée par un modèle NARX [4] [7]. Par conséquent, le modèle NARX est fréquemment utilisé pour la description et l'identification de système.

Si on dispose des mesures de l'entrée 'u' et de la sortie 'y' du processus à l'instant discret 'k' présent et à des instants antérieurs, le modèle doit permettre d'estimer la sortie y jusqu'à un horizon futur. Les relations établies relient les entrées-sorties passées du système et la sortie à l'instant futur k+1. Ce type de relation correspond parfaitement à notre méthode de diagnostic de défaut sur l'électrovanne. En effet un défaut est détecté en fonction des données actuelles en entrée et le passé très récent des sorties.

Le modèle dynamique Takagi-Sugeno en temps discret sous la forme Non Linéaire Auto-Régressive avec entrée eXogène (NARX), établi une relation entre les valeurs précédentes des entrées et sorties avec la sortie prédite  $\hat{y}$ , de la manière suivante :

$$\hat{y}(k+1) = f_{NL}(y(k), \dots, y(k-n_y + 1), \dots, u(k-n_u + 1)) \quad (2-17).$$

où k est l'instant d'échantillonnage,  $n_y$  et  $n_u$  sont des entiers liés à l'ordre (structure) du système. Une fois que la structure appropriée est établie, la fonction  $f_{NL}$  peut être approximée en utilisant une régression statique non linéaire. Le vecteur de régression x du modèle NARX est composé par un certain nombre d'entrées et de sorties précédentes ;

$$x = [y(k), \dots, y(k-n_y+1), u(k), \dots, u(k-n_u+1)]^T \quad (2-18).$$

tel que  $\hat{y}(k+1)$  est la sortie prédite.

L'objectif de l'estimation est de trouver la fonction non-linéaire 'f' :  $f_{NL}$  minimisant l'erreur de prédiction des moindres carrés.

$$J_p = \frac{1}{N} \sum_{k=1}^N (\tilde{y}(k))^2 = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2, \quad (2-19).$$

N : nombre d'observation

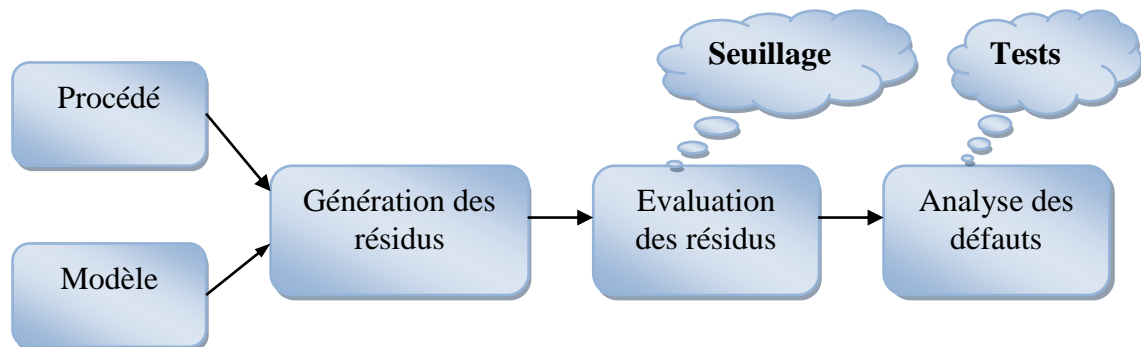
On vient de présenter le principe de la modélisation floue de type TS de la forme

$\hat{y}(k+1) = f(x(k))$ , où les paramètres sont identifiés en utilisant certains algorithmes d'apprentissage. Au chapitre IV nous donnerons des développements concernant l'estimation de ces paramètres.

## II.6. La méthode FDI:

### II.6.1. Introduction:

L'approche traditionnelle au diagnostic de défaut la plus utilisée est la redondance matérielle, qui emploie de multiple capteur, actionnaires et d'autres composants du système pour mesurer et contrôler certaines variables. Le schéma de diagnostic peut être construit en se basant sur la comparaison et l'analyse des données collectées. Ensuite on évalue si les performances du système en fonctionnement satisfont les spécifications des opérations du processus. Des méthodes moins coûteuses basées soit sur les données soit sur les lois systèmes ont été développées pour les processus industriels modernes [12] [13]. Ces méthodes de diagnostic dites FDI (Fault Détection and Isolation) basées sur des modèles utilisent des signaux résidus qui indiquent les changements entre le processus réel et son modèle (figure 1.15).



**Fig. 2.14** : Principe de la méthode FDI.

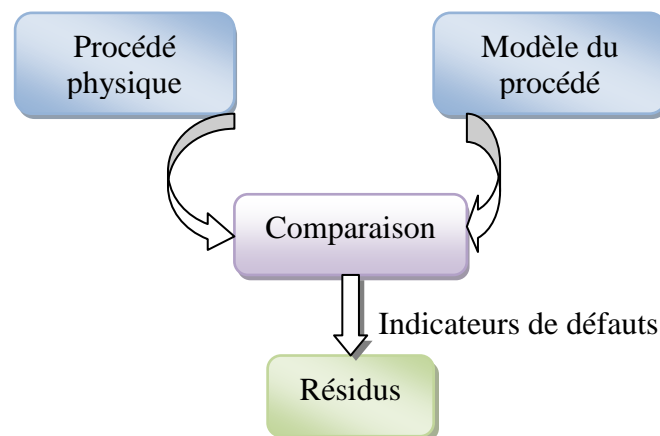
Notre principal axe de recherche est l'utilisation de la logique floue pour la détection et l'isolation de défaut, celle-ci à la capacité d'utiliser des connaissances quantitatives et qualitatives simultanément. La méthode FDI à base de raisonnement flou est un outil puissant pour la description du comportement du système par des relations **Si...Alors**.

La méthode FDI qui est largement interprétée dans la littérature, peut être : Sûr (un seul candidat responsable de défaut), ou probabiliste (le plus probable candidat responsable de défaut). Elle fait intervenir les techniques de base suivante : [26]

- ✓ la génération de résidus
- ✓ la détection
- ✓ et l'isolation des différents défauts qui apparaissent dans le système au fil du temps.

### II.6.2. Génération des résidus:

La première étape de la méthode FDI consiste à générer des indicateurs de défauts qui contiennent des informations sur les anomalies ou dysfonctionnements du système à surveiller. Le principe est de mesurer l'écart entre les mesures des signaux du procédé et la valeur théorique fournie par le modèle dans des conditions de fonctionnement nominal [27].



**Fig. 2.15** : Principe de génération de résidus

La génération des résidus se décompose en trois groupes : [13] [28]

- ✚ Approche par estimation de paramètres : déterminer le vecteur de paramètres à partir d'un ensemble de mesures de l'installation et l'ensemble de paramètres réalisés par le modèle.
- ✚ Approche par espace de parité : l'idée de base est de vérifier la cohérence entre les relations mathématiques du système et les mesures (relations de redondance analytiques). Il existe deux types de redondance analytique :

- redondance statique;
- redondance dynamique.

✚ Approche à base d'observateurs : un observateur d'état (reconstructeur d'état) est un système dynamique qui reçoit en entrée les sorties et les entrées du processus réel et dont la sortie est un vecteur des résidus si l'on souhaite faire du diagnostic.

### II.6.3. Principe de détection:

C'est l'aptitude du système de diagnostic à la détection des défauts sur le procédé. L'un des problèmes le plus délicat à résoudre dans la démarche de diagnostic est la prise de décision à retenir en fonction des écarts entre les signatures normales et les signatures caractéristiques d'un défaut [13]. La phase principale de la détection à base de raisonnement flou s'appuie sur la fuzzification du signal d'entrée, cette dernière nécessite la détermination de la plage de variations possibles de l'entrée considérée, nombre des ensembles flous et les fonctions d'appartenances de chaque ensemble. A savoir, des sous ensembles très larges risquent d'engendrer une non-détection et dans le cas contraire, on tombe sur le problème de fausses alarmes. La problématique est donc de trouver des paramètres de la fonction d'appartenance qui seront le compromis idéal entre le taux de fausse alarme et le taux de non-détection [26] [28]. Pour notre cas le seuil est déterminé par une fonction d'appartenance centrée trapézoïdale, les côtés montants et descendants du trapèze étant fonction de la variance du bruit et des perturbations [29].

Les éléments nécessaires à la détection de défauts sur un système réel sont : [12]

- ✚ le modèle de représentation du procédé réel;
- ✚ la fonction de comparaison du procédé réel par rapport à son modèle;
- ✚ la fonction de détection de défaut qui analyse les quantités de comparaison fournies précédemment.

### II.6.4. Localisation:

C'est la capacité du système de diagnostic à remonter directement à l'origine du défaut lorsqu'une panne a été détectée. Une alarme engendre bien souvent de nouvelles alarmes, d'où la difficulté de retrouver l'organe défaillant [30]. Ces pannes en cascade masquent la cause

réelle de la panne. Il est plus difficile de dégager une méthode systématique pour la fonction de localisation de défauts, chaque cas particulier est à prendre en considération. Néanmoins les méthodes courantes pour accéder à la localisation du défaut sont [12] [13]:

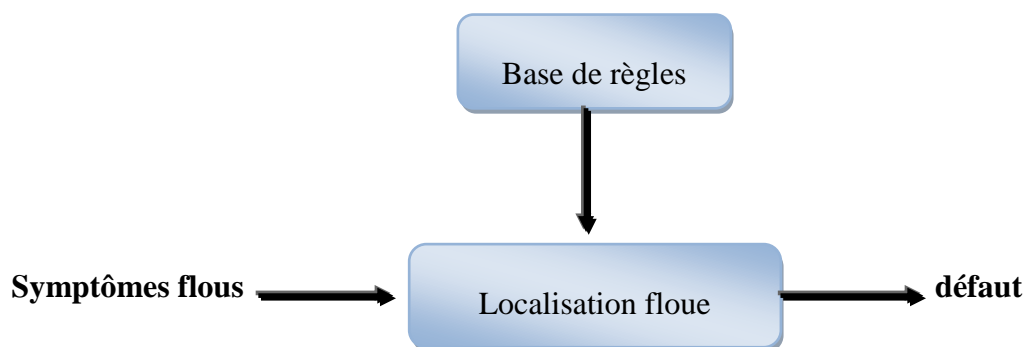
- ✚ l'analyse des conditions d'apparition du défaut;
- ✚ l'utilisation d'un modèle comportant le défaut supposé à la place d'un modèle de comportement normal;
- ✚ des essais de fonctionnement du système après l'apparition du défaut si cela reste possible (fonctionnement en mode test).

Notre méthode de diagnostic s'appuie sur l'utilisation de la logique floue pour l'évaluation des résidus et la localisation d'un défaut. Cette technique offre la possibilité d'identifier un défaut avec un degré de validité, en cas d'impossibilité d'isolation elle nous permet de conclure sur son existence. Ceci représente une aide appréciable pour l'opérateur.

Exemple (2.2) :

**Si** "resX = N" Et "resF=P" **Alors** "défaut = f<sub>2</sub>"

où : N et P sont des ensembles flous connus représentés par une fonction trapézoïdale.



**Fig. 2.16 :** Principe de localisation floue

Le principal avantage d'utiliser un système d'inférence floue pour le diagnostic est sa capacité à intégrer les connaissances expertes. Celles-ci sont fournies par la base de règles.

III.1. Introduction.

III.2. Méthode de détection.

III.2.1. Principe d'évaluation des résidus.

a) Génération des résidus.

b) Evaluation des résidus.

III.3. Méthode d'isolation.

III.4. Application.

III.5. Commentaires.

III.6. Influence de CV.

III.7. Conclusion.

### III.1. Introduction:

Ce chapitre est consacré à l'exploitation du modèle Simulink de l'électrovanne pour la mise en œuvre d'une méthode de détection et de décision. Notre approche à ce problème de diagnostic est issue des méthodes dites « intelligentes », elle repose entièrement sur la théorie de la logique floue. Nous allons montrer qu'il est possible avec des méthodes de raisonnement flou [31] moins complexes que certains algorithmes, on aboutit à des résultats similaires [32]. Les simulations de ce chapitre constituent pour nous une excellente introduction à l'étude du benchmark de l'électrovanne, et aux techniques de simulation sur son modèle Simulink. On présente d'abord les méthodes et principes pour détecter et isoler un défaut, ensuite nous les appliquons à quelques défauts de l'électrovanne.

### III.2. Méthode de détection:


Notre méthode de détection consiste à générer un résidu selon le schéma du paragraphe II.4. Ensuite par un algorithme flou on analyse ce résidu. La sortie de ce module de détection nous renseigne sur l'occurrence ou non d'un défaut. Un algorithme de détection flou est caractérisé par :

- L'univers de discours.
- Le nombre de sous-ensembles flous.
- Les fonctions d'appartenance, à savoir leur forme et leur distribution sur l'univers de discours.
- Les règles d'inférence.
- La logique de décision.

- **La fonction d'appartenance trapézoïdale:**

La fonction d'appartenance permet d'évaluer le signal résidu. En effet, le résidu doit indiquer si un défaut est apparu. Il doit être différent de zéro ou proche de zéro en l'absence de défaut, mais nettement différent de zéro en présence de défaut. Cette distance du résidu par rapport au zéro est estimée à l'aide d'une fonction d'appartenance [30]. Nous avons choisis la fonction trapézoïdale qui correspond parfaitement à notre méthode d'évaluation de la distance. On présente d'abord cette fonction, ensuite on expose la méthode d'évaluation.

La fonction d'appartenance trapézoïdale est caractérisée par 4 paramètres [4] : a, b, c et d, qui sont les coordonnées des sommets du trapèze (figure 3.1).



**Fig. 3.1 :** La fonction d'appartenance trapézoïdale

La fonction d'appartenance d'un élément  $x$  se calcule de la façon suivante :

$$\mu(x) = \begin{cases} 0 & x < a \\ (x-a)/(b-a) & a < x < b \\ 1 & b < x < c \\ (d-x)/(d-c) & c < x < d \end{cases} \quad (3-1).$$

### III.2.1. Principe d'évaluation des résidus :

On a vu auparavant que le signal résidu oscille autour de zéro en l'absence de défaut. Si par contre un défaut est apparu il s'éloigne vers des valeurs plus positives ou plus négatives. On en déduit l'existence de trois zones : la zone **Z** (Zéro: **0**), la zone **P** (Positive: **+1**) et la zone **N** (Négative: **-1**). Ainsi donc en fonction de l'état du système le résidu sera localisé dans l'une de ces trois zones. Chaque zone sera décrite par une fonction d'appartenance respectivement :  $\mu_0$ ,  $\mu_{+1}$ ,  $\mu_{-1}$ . L'application de ces trois fonctions au signal résidu déterminera la zone d'appartenance du résidu. En absence de défaut le signal résidu appartient à la zone **Z**, par contre en présence de défaut il sera soit dans la zone **P** ou dans la zone **N**. Dans chaque cas un degré d'appartenance est calculé [26].




Fig. 3.2 : Fuzzification du résidu.

Entre les trois fonctions d'appartenance, les zones de chevauchement appartiennent au domaine flou. Ainsi chaque fonction possède une zone de certitude ( $\mu = 1$ ) et une zone floue. En milieu industriel les installations peuvent se trouver dans un état sain mais avec une tendance vers un défaut ou bien un défaut qui vient d'apparaître avec une faible intensité. Ce genre de situations peut être détecté par l'algorithme grâce à l'existence de zones floues. Une telle information sur l'existence d'un défaut avec un certain degré d'accomplissement est essentielle pour l'opérateur qui doit être prêt à intervenir [5].

- **Détermination des paramètres de la fonction  $\mu_0$ :**

On détermine d'abord les paramètres de la fonction d'appartenance  $\mu_0$ , qui décrit le sous-ensemble flou des valeurs de résidu correspondant à un fonctionnement sain. Ces paramètres seront calculés en fonction des paramètres statistiques du signal résidu. Les histogrammes de la figure 3.3, montrent une distribution gaussienne des résidus pour un fonctionnement sans défauts. Nous savons que d'un point de vue statistique 95% de l'ensemble des points de résidu appartiennent au segment **bc** (petite base) de la fonction trapèze (figure 3.1) si :  $|bc| = 4\sigma$  avec  $\sigma$  l'écart-type [33]. En centrant la fonction trapèze autour de la valeur moyenne  $\bar{m}$  des points de résidu, la longueur de la petite base est :  $bc = \pm 2\sigma$ .





Fig. 3.3 : Histogrammes : (a)- résidus F, (b)- résidus X pour un système sain.

Les zones correspondantes aux pentes sont fixées à 25% de la surface du rectangle, les deux autres fonctions correspondantes aux zones **P** et **N** seront déduites directement de la fonction  $\mu_0$ . Les pentes dans les zones floues sont complémentaires. Le domaine de variation du signal résidu est compris entre +1 et -1 [26] [31].

La figure (3.4) représente les fonctions d'appartenance d'un comportement sain pour les signaux resF et resX, respectivement.




**Fig. 3.4 :** Les fonctions d'appartenances pour les deux résidus resF et resX.

Ces différentes fonctions d'appartenance représentent des seuils pour les résidus. Ces seuils sont déterminés en tenant compte du bruit affectant les résidus. Les côtés montants et descendants du trapèze étant fonction de la variance du bruit et des perturbations. Ces perturbations affectent le modèle Simulink et les mesures produites sur l'installation. Puisqu'on utilise des degrés d'appartenance d'un résidu à un seuil flou représenté à l'aide de sous-ensembles flous, ceci confère une certaine robustesse à l'algorithme de détection [5].

#### a) Génération des résidus:

Les résidus sont générés selon le schéma de simulation présenté au paragraphe II.4. Le fichier de données [34] [35] renferme des mesures réelles de variables de l'actionnaire. Ces mesures sont ceux de la campagne 2001 [15], et correspondent à un fonctionnement sain de l'électrovanne avec une période d'échantillonnage de 1s. Le block Act simule le mécanisme de fonctionnement de l'électrovanne. Et pour que ce modèle reproduise le plus fidèlement possible l'actionnaire, il doit produire en sortie les mêmes signaux que l'organe réel. On injecte à l'entrée du modèle les signaux issus du fichier, et en absence de défaut on retrouve des signaux résidus oscillant autour d'une valeur moyenne pratiquement nulle (**Fig. 3.5**)



**Fig. 3.5** : Résultats de simulation pour un modèle sans défaut.

On définit :  $\text{resX} = X_m - X_{es}$ .

$\text{resF} = F_m - F_{es}$ .

avec :  $X_m$  et  $F_m$  : variables mesurées.

et  $X_{es}$  et  $F_{es}$  : variables de sortie estimées par le modèle.

### b) Evaluation des résidus:

Pour détecter un défaut on doit évaluer les résidu pour déterminer la zone d'appartenance (Z, P, N) et déduire un degré d'accomplissement de ce défaut. Cette évaluation est identique dans son principe pour les deux résidus  $\text{resX}$  et  $\text{resF}$ , on notera par la suite le signal résidu par la variable  $r$ . Il est clair que notre programme traite simultanément les deux résidus  $\text{resX}$  et  $\text{resF}$ . Pour chaque point  $i$  de  $\mathbf{r}$  on calcule les degrés suivants [26] [36] :

$$\mu_i = \{ \mu_{i,0}, \mu_{i,1}, \mu_{i,-1} \} \quad i = 1, \dots, n. \quad (3-2).$$

où :  $\mu_{i,0}$  : degré d'appartenance du  $i^{\text{eme}}$  résidu à la zone Z.

$\mu_{i,1}$  : degré d'appartenance du  $i^{\text{eme}}$  résidu à la zone P.

$\mu_{i,-1}$  : degré d'appartenance du  $i^{\text{eme}}$  résidu à la zone N.

A partir de ces degrés  $\mu$  on en déduit un signal symptôme  $S_i$  prenant une valeur dans l'ensemble :

$$S_i = \{ \langle \mu_{i,0}, 0 \rangle, \langle \mu_{i,1}, 1 \rangle, \langle \mu_{i,-1}, -1 \rangle \} \quad (3-3).$$

On illustre cette technique à l'aide des figures 3.6 et 3.7




Fig. 3.6 : Evaluation floue du signal résidu.




Fig. 3.7 : Evaluation floue du  $i^{\text{eme}}$  résidu.

La détermination du degré d'appartenance est immédiate lorsque le résidu est en dehors des zones de chevauchements :  $\mu_i=1$ . Par contre dans les zones floues on doit estimer ce degré à l'aide des opérateurs flous. On considère les deux points d'intersection  $x_1, x_2$  (Fig. 3.8), et on calcule pour différents cas possible les deux valeurs  $\mu_i$  et  $S_i$  comme suit :

**Intervalle (a b):**

- Si  $r < x_1$  alors

$$\left\{ \begin{array}{l} \mu_i = \max \{ \mu_{i,0}, \mu_{i,-1} \} \quad i = 1, \dots, n. \\ \text{et} \\ S_i = \{ \langle \mu_{i,-1}, -1 \rangle \} \end{array} \right. \quad (3-4).$$

- Si  $res > x_1$  alors

$$\left\{ \begin{array}{l} \mu_i = \max \{ \mu_{i,0}, \mu_{i,-1} \} \quad i = 1, \dots, n. \\ \text{et} \\ S_i = \{ \langle \mu_{i,0}, 0 \rangle \} \end{array} \right. \quad (3-5).$$

**Intervalle (c d):**

- Si  $res < x_2$  alors

$$\left\{ \begin{array}{l} \mu_i = \max\{ \mu_{i,0}, \mu_{i,1} \} \quad i = 1, \dots, n. \\ \text{et} \\ S_i = \{ \langle \mu_{i,0}, 0 \rangle \} \end{array} \right. \quad (3-6).$$

- Si  $res > x_2$  alors

$$\left\{ \begin{array}{l} \mu_i = \max\{ \mu_{i,0}, \mu_{i,1} \} \quad i = 1, \dots, n. \\ \text{et} \\ S_i = \{ \langle \mu_{i,1}, 1 \rangle \} \end{array} \right. \quad (3-7).$$

$$\text{Avec : } \left\{ \begin{array}{l} 0 \leq \mu_i \leq 1 \\ 0 \leq \sum_{i=1}^n \mu_i \leq 1 \end{array} \right. \quad (3-8).$$

- **Règles d'évaluation floue :**

Les règles d'évaluation floue des résidus sont récapitulées comme suit :

**R1 : Si** ( $r_i$  est N) **Alors** ( $S_i = -1, \mu_i = 1$ ).

**R2 : Si** ( $a < r_i < x_1$ ) **Alors** ( $S_i = -1, \mu_i = \max\{ \mu_{i,-1}, \mu_{i,0} \}$ ).

**R3 : Si** ( $x_1 < r_i < b$ ) **Alors** ( $S_i = 0, \mu_i = \max\{ \mu_{i,-1}, \mu_{i,0} \}$ ).

**R4 : Si** ( $r_i$  est Z) **Alors** ( $S_i = 0, \mu_i = 1$ ).

**R5 : Si** ( $c < r_i < x_2$ ) **Alors** ( $S_i = 0, \mu_i = \max\{ \mu_{i,1}, \mu_{i,0} \}$ ).

**R6 : Si** ( $x_2 < r_i < d$ ) **Alors** ( $S_i = +1, \mu_i = \max\{ \mu_{i,1}, \mu_{i,0} \}$ ).

**R7 : Si** ( $r_i$  est P) **Alors** ( $S_i = +1, \mu_i = 1$ ).

- **Algorithme de détection flou:**

Notre algorithme démarre par la détermination des fonctions d'appartenance, ensuite et à chaque instant  $i$  il analyse les deux résidus  $resX$  et  $resF$ . Cette analyse consiste à appliquer les

règles précédentes (R1 à R7). Dès qu'un signal symptôme  $S_i$  d'un défaut est détecté on poursuit l'analyse jusqu'à un horizon de 10 valeurs, soit 10 secondes. Si ce symptôme est maintenu durant ces 10 secondes, on déclare l'apparition d'un défaut. Ce module de détection reçoit en entrée les deux résidus  $resX$  et  $resF$ .

**L'algorithme:**

**Etape 1 :** calcule des paramètres (a, b, c, d) de  $\mu_0$

**Etape 2 :** application des règles d'évaluation floue

**Etape 3 :**  $S_i$  différent de 0

**oui :** continue test jusqu'à  $i=10$

$S_i$  toujours différent de 0

**oui :** étape 4

**non :** étape 2

**non :** retour étape 2

**Etape 4 :** déclaration d'un défaut.

**Etape 5 :** retour à l'étape 2.

**➤ Remarques :**

1/- En milieu réel de fonctionnement, la détection est une opération qui ne s'arrête pas. Les mesures fournies par le système SCADA sont traitées par un modèle de surveillance. Pour notre algorithme on a fait de même, le programme boucle sur lui-même. Il est clair que pendant les simulations on sera limité par la taille du fichier de mesures.

2/- Le choix d'un horizon de 10 secondes pour confirmer le défaut a été étudié en tenant compte des signaux résidus. Certains de ces signaux ont une transitoire positive ou négative de durée parfois inférieure à 10s lorsque l'intensité du défaut est moyenne. L'exemple du défaut f10 dont les signaux sont représentés par les figures 3.9 et 3.10 montre clairement la difficulté de diagnostic lorsque le biais est pratiquement un transitoire.

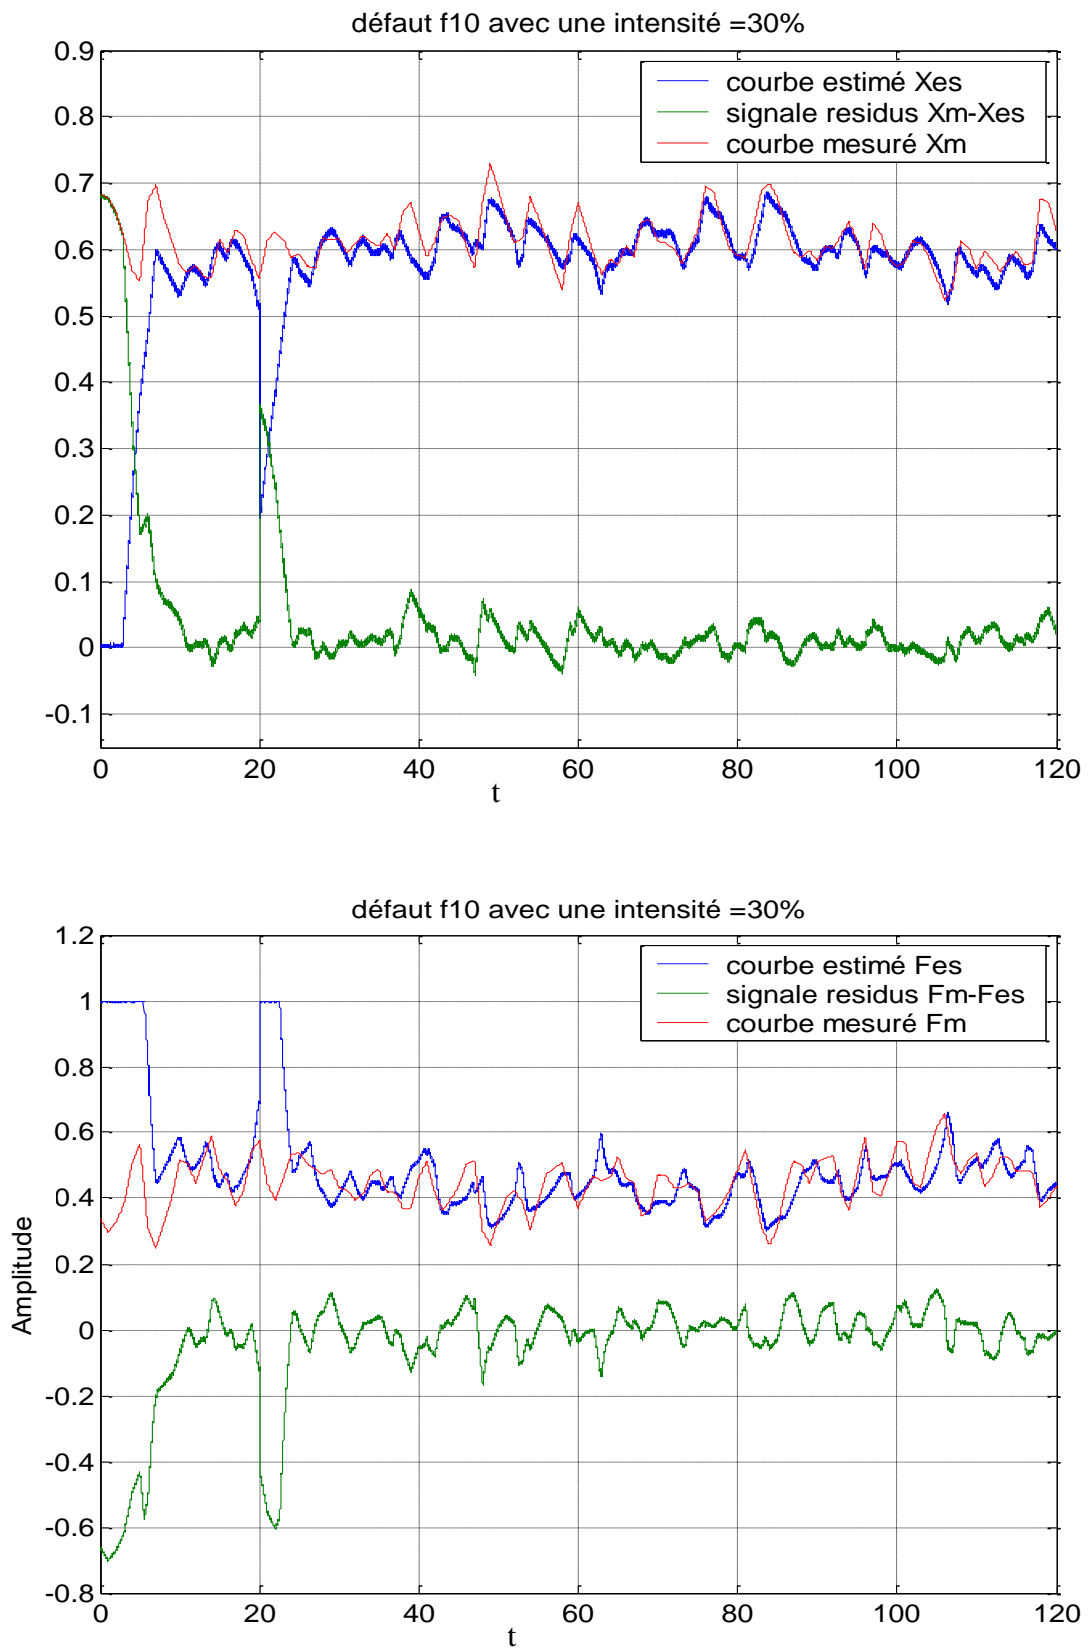


Fig. 3.8 : Simulation de résidus X et F provoqué par le défaut f10 d'intensité = 30%.

### III.3. Méthode d'isolation:

L'isolation de défaut consiste à désigner le défaut responsable du biais observé sur les résidus. Cela suppose obligatoirement la connaissance des symptômes des différents défauts retenus pour notre étude. Ces symptômes sont parfaitement identifiés après avoir simulé ces défauts et observer les deux résidus  $resX$  et  $resF$ . On pose  $r_1 = resX$  et  $r_2 = resF$ , on note alors  $S_i$  le signal symptôme avec  $i=1,2$  correspondant à  $r_i$ . Les signaux symptômes calculés lors de l'évaluation des résidus sont une représentation qualitative de ces résidus. Pour résoudre ce problème d'isolation de défaut par la logique floue on met en œuvre un raisonnement à base de règles intégrant les relations symptômes/défauts sous forme « **Si...Alors** ». Cet algorithme d'isolation reçoit en entrée les signaux symptômes  $S_i$ . C'est aux niveaux de ces règles que les connaissances expertes peuvent être rajoutées, d'où la grande simplicité d'utilisation de ce type de raisonnement flou. Il est clair que les défauts possédants des symptômes semblables seront difficiles à isoler, à moins que si l'on fasse intervenir les intensités des défauts.

- **Principe de la méthode:**

Dans un souci de simplicité on expose le principe de cette méthode pour le cas de deux résidus. La généralisation à plusieurs résidus est immédiate. Le module de détection délivre un vecteur  $V_i$  pour chaque résidu  $r_i$  contenant le signal  $S_i$  et  $\mu_i$ . Les antécédents des règles seront les symptômes et la conclusion sera le défaut correspondant à ces symptômes. Pour un défaut  $f_k$  on détermine le degré d'activation de la règle comme suit [36] :

$$\mu(f_k) = \mu(s_1 \in V_k) \otimes \mu(s_2 \in V_k) \quad (3-9).$$

$\otimes$  : Opérateur de conjonction floue.

$\mu(f_k)$  : Niveau d'activation de la règle pour le  $k^{eme}$  défaut.

Exemple (3.1): Exemple de règle d'un raisonnement d'isolation flou :

**Rk : Si**  $[(s_1 = 0)] \cap [(s_2 = +1)]$  **Alors** défaut  $f_k$ .

### III.4. Application :

Le benchmark définit 19 types de comportement défectueux pour lesquels seulement 14 défauts ont un comportement brusque (F1, F2, F7, F8, F10, F11, à ..., F19). Dans ce mémoire on s'intéresse uniquement à ce type de défauts, puisqu'ils sont responsables de perturbations de la production et de sa qualité de manière instantané, et on doit corriger le défaut rapidement, d'où la nécessité d'un diagnostic en temps réel. La différence de pression entre la pression d'entrée P1 et la pression de sortie P2 permet de distinguer le défaut f17 parmi les autres défauts. Le comportement des trois défauts (F8, F12, F14) est non distinguable par rapport au comportement normal (sain). Pour notre application nous considérons quatre défauts (F1, F10, F13 et F19), appartenant chacun à une partie de l'électrovanne, respectivement le corps de la vanne, le servomoteur, le positionneur et un défaut externe. Les défauts ont été simulés avec trois intensités différentes (30%, 50% et 90%). Le défaut est injecté à l'instant  $t=20s$  comme indiqué sur la figure 3.8. Les symptômes de ces défauts étant connus, il suffit d'appliquer le raisonnement flou suivant pour isoler un défaut

#### ✓ Règles d'isolation floue :

**R1** : Si  $(s_1 = +1) \cap (s_2 = -1)$  Alors défaut **f<sub>1</sub>**.

**R10** : Si  $(s_1 = +1) \cap (s_2 = -1)$  Alors défaut **f<sub>10</sub>**.

**R13** : Si  $(s_1 = 00) \cap (s_2 = -1)$  Alors défaut **f<sub>13</sub>**.

**R19** : Si  $(s_1 = 00) \cap (s_2 = +1)$  Alors défaut **f<sub>19</sub>**.

Le défaut  $f_k$  isolé est déclaré avec son niveau d'activation  $\mu(f_k)$ .

Les trois premiers tableaux qui suivent décrivent les différents résultats de détection obtenue avec 03 largeurs différentes de la zone « Z » ce qui montre l'influence du choix de l'écart type sur le diagnostic.

	30%	50%	90%
f1	ND	D	D
f10	ND	ND	D
f13	D	D	D
f19	ND	ND	D

**Tableau 3.1** : résultats de détection pour  $Z = 6\sigma$ .

	30%	50%	90%
f1	ND	D	D
f10	ND	ND	D
f13	D	D	D
f19	ND	ND	D

Tableau 3.2 : résultats de détection pour  $Z = 3\sigma$ .

	30%	50%	90%
f1	ND	D	D
f10	ND	ND	D
f13	D	D	D
f19	D	D	D

Tableau 3.3 : résultats de détection pour  $Z = 2\sigma$ .

Si / fi	f1	f10	f13	f19
S1	1	1	0	0
S2	-1	-1	-1	1

Tableau 3.4 : Table de correspondance symptômes/défauts.

Avec D : détecté.

ND : non détecté.

S<sub>1</sub> : signature de X.

S<sub>2</sub> : signature de F.

### III.5. Commentaires :

Le générateur de résidu permet de construire des signaux sensibles aux différents défauts à détecter. La comparaison de ces signaux à des seuils de détection fournit une signature qui, comparée à la table des signatures permet la localisation des défauts. En effet, la signature peut s'interpréter comme une forme qu'il s'agit de reconnaître parmi l'ensemble des différentes formes possibles représentées par la table des signatures. Notre programme de détection fait passer une fenêtre de balayage de largeur égale à 10 points dont le but est l'analyse des 10 points successive du signal résidu, dans le cas où le signal résidu appartient à la zone Z on peut dire que le système est sain et dans le cas contraire on déclare la présence d'un défaut. En pratique, le problème de définition du seuil de détection « Z » n'est pas si

simple car les grandeurs mesurées sont toujours entachées de bruits. D'autre part, le modèle utilisé n'est qu'une représentation toujours imparfaite de la réalité, de sorte que les résidus peuvent être non nuls en l'absence de défaut. Toutefois, le problème se pose du choix de la valeur de ce seuil. En effet, un seuil très faible risque d'entraîner de fausses alarmes alors qu'un seuil trop important risque d'entraîner la détection d'un défaut trop tardive, voire de le laisser complètement inaperçu. Une approche simple consiste à fixer le seuil par rapport aux caractéristiques statistiques des résidus pour un fonctionnement normal de l'installation. Ainsi, connaissant la moyenne et l'écart type des résidus, on peut ajuster la largeur  $Z$  à la valeur moyenne plus ou moins un, deux ou trois fois l'écart type [13]. Pour un premier essai nous avons prit  $Z = 6\sigma$ , qui représente 99,73% de la superficie totale de la distribution du signal résidu, mais on s'est trouvé face à un problème de non détection des défauts à faible et moyenne intensité. Pour cela nous avons varié la largeur de la zone  $Z$  de  $6\sigma$  à  $3\sigma$  et  $2\sigma$  et pas moins pour ne pas tomber dans le cas des fausses alarmes. Les tableaux ci-dessus montre le résultat du module d'évaluation et de détection des quatre défauts (f1, f10, f13, f19) pour trois différentes intensités, prenant par exemple le cas du défaut f19 à faible (30%) et moyenne (50%) intensité, on remarque qu'il est détectable que pour  $Z = 2\sigma$ . Les signatures produites par le module d'évaluation des résidus sont comparés à la table de signature symptôme / défaut pour pouvoir isoler les différents défauts. La figure 3.9 résume les différentes étapes du diagnostic [13].

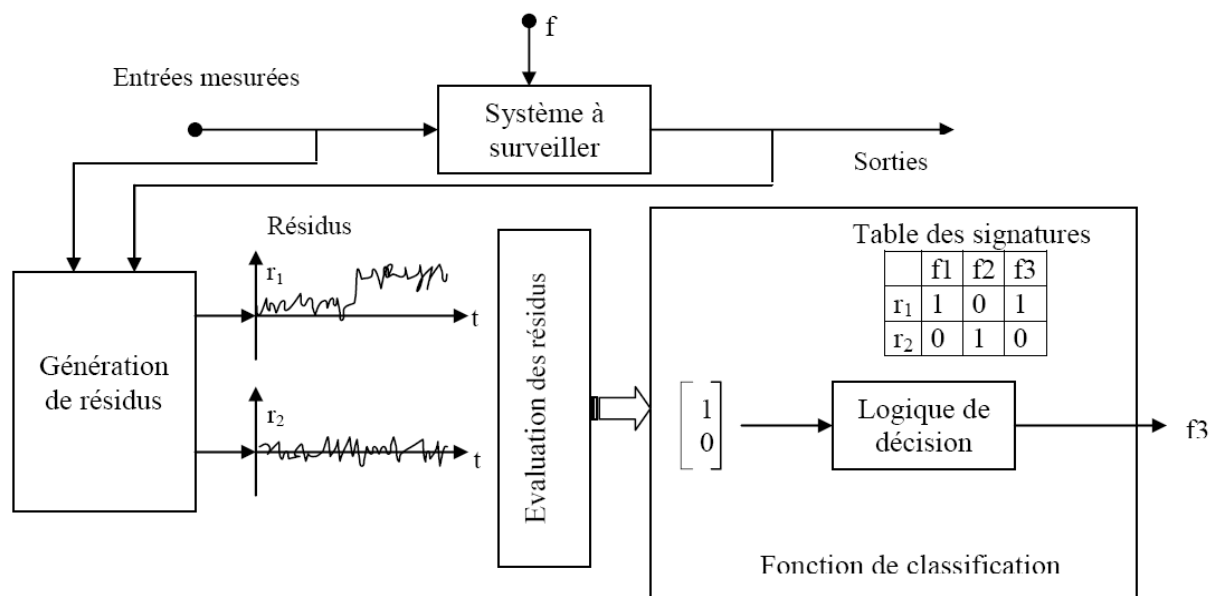




Fig. 3.9: Détection et localisation des défauts.

Les figures (3.10) (3.11) représentent l'allure des histogrammes des variables aléatoires resX et resF à la présence du défaut f19 avec une intensité égale à 90%, ces histogrammes ont été calculés en prenant 120 échantillons temporels.



**Fig. 3.10:** Histogramme de resF avec f19=90%.



**Fig. 3.11:** Histogramme de resX avec f19=90%.

La distribution de beaucoup de paramètres industriels correspond fréquemment à une loi normale [33]. On compare souvent l'histogramme obtenu au profil « en cloche » de la loi normale. L'allure de l'histogramme de resF à la présence du défaut f19, montre un mélange de deux lots ayant une moyenne différente, on remarque que la majorité des points sont distribués autour de la valeur moyenne «  $m=0.35725$  » par contre, les valeurs de resX sont distribués autour de la valeur moyenne «  $m=0.0093619$  ». Pour un système sain (**Fig. 3.3**) les valeurs aléatoires des resF et resX sont centrées respectivement autour des valeurs moyennes 0.0051947 et 0.0093619. Par contre, à la présence du défaut f19, seul la répartition des valeurs de resF qui change, cette translation vers le sens positif s'explique par l'appartenance du signal resF à la zone « P » ce qui implique  $S2 = +1$ . Revenons aux signatures de la table de correspondance symptômes / défauts, le défaut f19 est caractérisé par : 
$$\begin{bmatrix} S1 \\ S2 \end{bmatrix} = \begin{bmatrix} 0 \\ +1 \end{bmatrix}.$$

### III.6. Influence de CV :

L'un des problèmes les plus connue dans le domaine de diagnostic industriel est les fausses alarmes, qui sont généralement due aux bruits. A cet effet, il est nécessaire que les techniques de diagnostic doivent être fiables même pour tels types de problème. En réalité les signaux ne sont jamais parfaitement filtrés. Pour cela, on s'est intéressé au signal externe de contrôle CV produit par l'automate, des signaux de 5% CV et 10% CV sont superposés au signal CV sur l'intervalle [20s 40s] afin de prendre en compte ce type de perturbation. Dans la suite de cette simulation, nous avons calculé pour chaque éléments CV(i) 5% et 10% sur un intervalle de 20 à 40s, ensuite prenant ce pourcentage en aditif +/- pour chaque élément de l'étendue. Finalement, l'ensemble des 04 fichiers de données +/- 5% et +/-10% seront injecter à l'entrée du modèle simulink, ce dernier à pour but d'extraire les resF et resX. Prenons le cas de +/- 10% CV, les figures ci-dessous montre la variation de resF et resX en fonction de CV pour le cas d'un système sain.

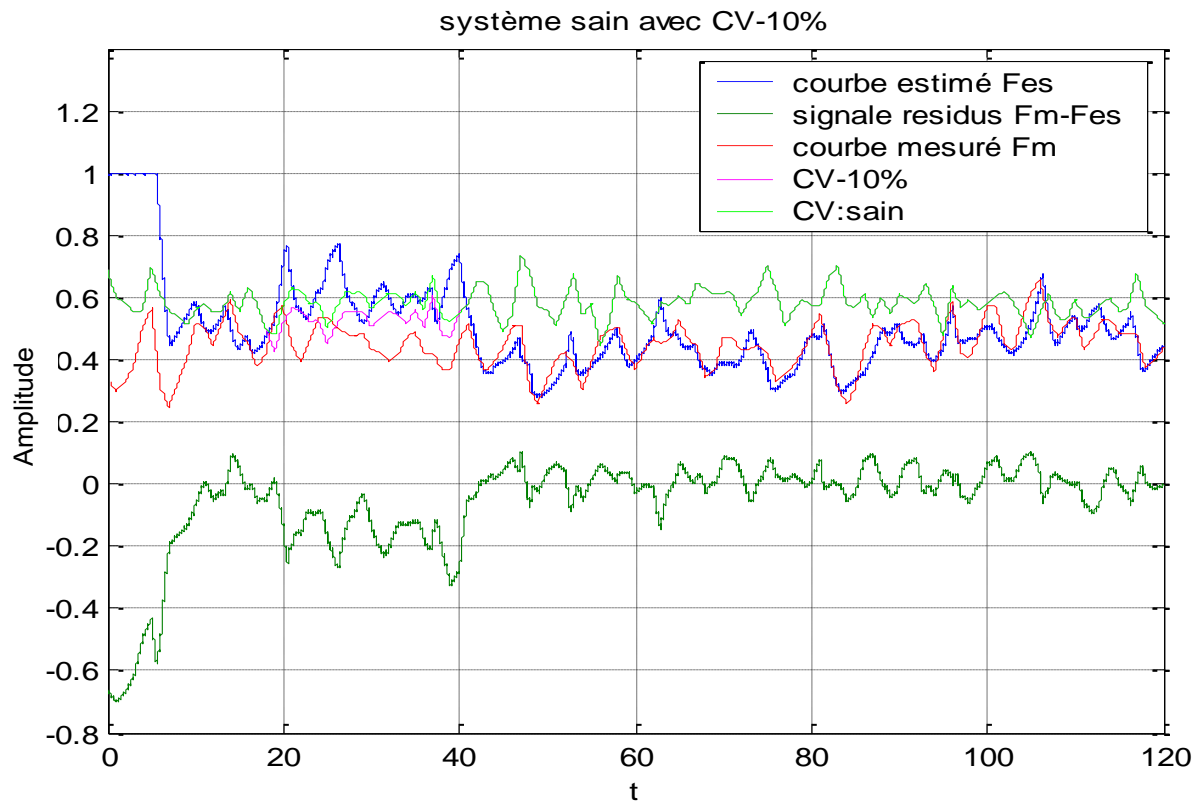



Fig. 3.12 : Simulation de resx et resF pour un système sain avec CV-10%.





Fig. 3.13 : Simulation de resF et resX pour un système sain avec CV+10%.

L'application des resF et resX d'un système sain aux modules d'évaluation et de détection, nous a conduit aux résultats résumés sur les tableaux suivants :

	CV	CV+10%	CV-10%	CV+5%	CV-5%
SS	ND	ND	ND	ND	ND

**Tableau 3.5** : résultats de détection pour  $Z = 6\sigma$ .

	CV	CV+10%	CV-10%	CV+5%	CV-5%
SS	ND	ND	ND	ND	ND

**Tableau 3.6** : résultats de détection pour  $Z = 3\sigma$ .

	CV	CV+10%	CV-10%	CV+5%	CV-5%
SS	ND	ND	ND	ND	ND

**Tableau 3.7** : résultats de détection pour  $Z = 2\sigma$ .

SS : système sain.

#### **+** **Interprétation :**

Les figures ci-dessus montre que les résidus sont parfaitement couplés du signal CV, observons l'intervalle [20 40]s on remarque que pour CV-10%, resX est inversement proportionnelle au signal CV contrairement au resF. Appliquons ces résidus au module d'évaluation et de détection, nous n'avons pas détecté des anomalies même pour une intensité élevé de : 10% CV. On explique le résultat de non détection des différentes variations imposé sur le signal CV par le bon seuillage choisis par rapport a (+/-5% et +/- 10%) CV.

### III.7. Conclusion :

Dans ce chapitre nous avons présenté une approche simple et pratique de détection et d'isolation de défauts basé sur le raisonnement flou, décrivant toutes les étapes nécessaires à la mise en place d'un système d'aide au diagnostic depuis la prise de mesure jusqu'à l'étape d'isolation. La propriété principale de la méthode de raisonnement floue est sa grande précision, elle manifeste également par le biais de manipulation fine dans les zones de chevauchement. L'un des problèmes le plus délicat à résoudre dans la démarche de diagnostic est la prise de décision à retenir en fonction des écarts entre les signatures normales et les signatures caractéristiques d'un défaut. Un seuillage trop élevés ne permettrait pas de détecter à temps un défaut, par contre des seuils trop bas déclencheraient trop de fausses alarmes. Dans notre travail nous avons étudié ce problème par la multiplication des fenêtres d'analyse de largeur différente ( $6\sigma$ ,  $3\sigma$  et  $2\sigma$ ), l'utilité de cette approche est remarquable dans le cas du défaut f19 tel que on n'a pas pu le détecter a faible (30%) et moyenne (50%) intensité qu'avec  $Z=2\sigma$ , mais malheureusement, ce n'est pas une solution idéal pour les défauts (f1, f10). Un autre problème que nous avons rencontré est l'insensibilité des résidus pour quelques défauts qui ont un comportement non distinguable par rapport au comportement normal (sain). Tel que, les défauts (F8, F12, F14). Sur le plan pratique, les perturbations ont rarement un effet négligeable, l'élaboration d'indicateurs de défauts insensibles aux perturbations parait donc primordiale.

IV.1. Introduction.

IV.2. Apprentissage du modèle TS.

IV.3. Construction du modèle TS.

IV.4. Modélisation basée sur des techniques de coalescence floue.

IV.4.1. Introduction.

IV.4.2. Algorithme de clustering flou.

IV.4.3. Obtention des paramètres des conséquents.

IV.4.4. Validation du modèle

IV.5. Application.

IV.5.1. Sélection des données et des variables.

IV.5.2. Utilisation du clustering flou GK.

IV.6. Conclusion.

### IV.1. Introduction:

Après avoir introduit des concepts de base sur la structure générale du modèle flou TS au chapitre II, dans lequel le conséquent des règles utilise des variables numériques sous la forme des fonctions. Le formalisme TS est mieux adapté à une démarche plus systématique pour la construction de modèles non linéaires multi-variable, grâce à leur bonne capacité d'interpolation numérique et d'apprentissage à partir des données [7]. Dans le cadre de notre travail, le modèle flou TS essaye de résoudre un problème complexe de modélisation en le décomposant en plusieurs sous problèmes plus simples. La théorie des ensembles flous offre alors un excellent outil pour représenter l'incertitude associée à la tâche de décomposition, en fournissant des transitions douces entre les sous modèles linéaires [25] et afin d'intégrer divers types de connaissance dans un même cadre. A ce propos, nous avons considéré la méthode de coalescence (clustering) floue GUSTAFSON-KESSEL(GK) [37] basées sur la minimisation itérative d'une fonction objective, afin de générer automatiquement la décomposition à partir des données entrée-sortie du système. Dans cette approche, le nombre de clusters correspond à celui des sous modèles linéaires dans le modèle TS.

### IV.2. Apprentissage du modèle TS:

Nous présentons ici un type spécial de réseaux neuro-flous. Il s'agit de l'approche ANFIS (système à inférence floue organisé en réseau adaptatif) [38]. Pour simplifier le modèle, nous considérons un système à deux entrées  $x_1$ ,  $x_2$  et une sortie  $y$ , les deux équations qui suivent sont les règles du modèle flou TS :

Si  $x_1$  est  $A_1$  et  $x_2$  est  $B_1$  Alors  $y_1 = f_1(x_1, x_2) = a_1x_1 + b_1x_2 + c_1$ .

Si  $x_1$  est  $A_2$  et  $x_2$  est  $B_2$  Alors  $y_2 = f_2(x_1, x_2) = a_2x_1 + b_2x_2 + c_2$ .

La représentation de cette base de règles par le réseau adaptatif est présentée par la figure 4.1.




Fig. 4.1 : (a) raisonnement flou-(b) Réseau ANFIS lié au modèle TSK.

Le réseau adaptatif ANFIS est un réseau multicouche dont les connexions ne sont pas pondérées ou elles ont toutes un poids égal à 1 [38]. Les nœuds sont de deux types différents selon leur fonctionnalité: des nœuds adaptatifs (carrés), et des nœuds fixes (circulaires).

Couche 1 : caractérise le degré d'appartenance de  $x$  par rapport aux sous-ensembles flous.

Couche 2 : engendre le degré d'activation d'une règle.

Couche 3 : la sortie du nœud  $i$  caractérise le degré d'activation normalisé de la règle  $i$ .

Couche 4 : la sortie de chaque nœud de la couche 4 est déterminée en fonction de la sortie de la couche 3 et de l'ensemble des paramètres de sortie de la règle  $i$ .

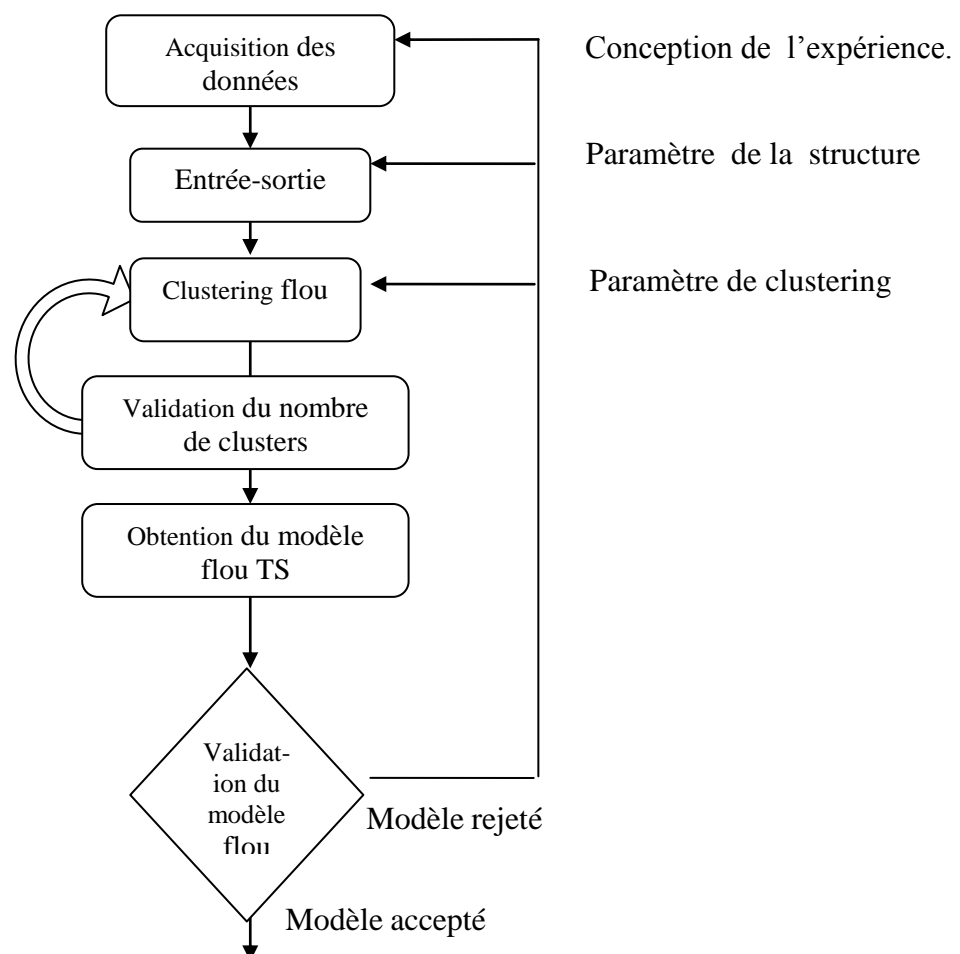
Couche 5 : est représentée par un nœud unique au niveau duquel s'effectue la somme des signaux provenant de la couche 4.

Le réseau ANFIS utilise, d'une part, un algorithme de clustering floue sur l'ensemble des données pour partitionner l'espace d'entrée, et d'autre part, un algorithme d'apprentissage pour simplifier les conclusions et éliminer les variables d'entrées non pertinentes.

### IV.3. Construction du modèle TS :

Nous abordons ainsi une description d'une méthodologie générale pour la construction du modèle flou TS, en mettant l'accent sur les besoins communs qui sont : la validation du nombre de clusters, la génération des fonctions d'appartenance des antécédents, l'obtention des paramètres des conséquents et la validation numérique du modèle final. L'organigramme suivant illustre la procédure de construction du modèle flou TS à partir des données, en utilisant des techniques de clustering. La procédure est itérative, dans la mesure où dans une même session de modélisation, on peut répéter certains pas afin de tester différents choix pour plusieurs paramètres.

#### ✓ Organigramme de la Méthodologie d'identification non linéaire basée sur l'approche de clustering flou :



**✓ Clustering flou:**

La localisation et les paramètres des sous modèles sont établis en partitionnant les données disponibles en clusters hyper ellipsoïdaux (GK). Chacun des clusters définit une région floue dans laquelle le système peut être approximé localement par un sous modèle linéaire (au moyen des conséquents). Pour l'algorithme de clustering GK, l'obtention des paramètres des conséquents du modèle TS correspondant est faite lors d'une étape postérieure au processus de clustering [7] [37].

**✓ Validation du nombre de clusters:**

L'utilisation des mesures de validation des clusters est une approche standard pour la détermination d'un nombre approprié de clusters dans un ensemble de données. Cette approche s'avère utile spécialement pour les méthodes de clustering qui nécessitent la sélection a priori du nombre de classes. L'analyse de validité des clusters est réalisée en exécutant l'algorithme de clustering pour différentes valeurs de « c », à plusieurs reprises pour chaque « c » avec une initialisation différente. La mesure de validité est calculée pour chaque exécution et le nombre de clusters qui optimise la mesure est alors choisi comme étant le nombre "convenable" de clusters pour l'ensemble des données. Les mesures de validité peuvent être aussi évaluées pour différentes structures du modèle.

**✓ Obtention du modèle flou TS :**

Un modèle flou de structure définie basé sur des règles est extrait de la matrice de partition floue disponible ainsi que des prototypes (centres) des clusters. Les règles, les fonctions d'appartenance et d'autres paramètres qui constituent le modèle flou sont obtenus de façon automatique.

**IV.4. Modélisation basée sur des techniques de clustering floue:****IV.4.1. Introduction:**

Les méthodes d'identification basées sur le Clustering floue sont des méthodes qui ont des liens avec les domaines de l'analyse des données et de la reconnaissance des formes. La partition des données est représentée dans la matrice de partition floue,  $\mu=[\mu_{ik}]$ , dont les éléments  $\mu_{ik}$  sont les degrés d'appartenance des points  $[x_k, y_k]$  dans des clusters flous avec prototypes  $v_j$ . Des règles floues de type "Si Alors" peuvent être extraites en projetant les

clusters sur les axes des coordonnées [7]. Le concept de similarité des données par rapport à un prototype permet d'envisager plusieurs formes possibles pour la définition d'une mesure de distance appropriée et le caractère du prototype. Par exemple, les prototypes peuvent être définis comme des sous-espaces linéaires (lignes, plans et hyperplans) ou bien comme des hyper ellipsoïdes avec une mesure adaptative de distance. Dans le modèle TS chaque cluster est représenté par une règle, Les Fonctions d'appartenance pour les ensembles flous sont générées par la projection point par point de la matrice de partition floue sur les variables des antécédents. Ces ensembles flous définis point par point peuvent être approximés par des fonctions paramétriques appropriées. Les paramètres du conséquent pour chaque règle peuvent être obtenus par l'intermédiaire d'une estimation de type moindre carré [7], que nous aborderons plus tard. La matrice des données prend la forme  $z = \{z_1, z_2, \dots, z_N\}$ . Chaque  $k^{\text{ème}}$

observation constitue un vecteur noté par  $Z_k = \{z_{1k}, z_{2k}, \dots, z_{nk}\}^T$ , avec  $1 \leq k \leq N$ ,  $Z_k \in \mathbb{R}^n$ , ou  $N$  représente le nombre des observations et  $n$  correspond au nombre de variables mesurées, attributs ou caractéristiques dans l'espace de représentation  $\mathbb{R}^n$ . un ensemble de  $N$  observations est dénoté par  $z = \{z_k | k = 1, 2, \dots, N\}$  et il est représenté par une matrice sous la forme:

$$z = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1N} \\ z_{21} & z_{22} & \dots & z_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ z_{n1} & z_{n2} & \dots & z_{nN} \end{bmatrix} \quad (4-1).$$

Une  $c$ -partition floue d'un ensemble  $Z$  peut être obtenue en définissant des  $c$ -sous-ensembles flous de  $Z$  tel que la somme des degrés d'appartenance pour chaque observation de  $Z$  soit unitaire. En fait, on associe à chaque observation  $Z_k$  appartenant à  $Z$  un vecteur de degrés d'appartenance aux différentes classes. La juxtaposition de ces vecteurs pour l'ensemble des  $N$  observations de  $Z$  amène à la définition d'une matrice d'appartenance. Une partition floue de  $Z$  est une famille de sous ensembles flous  $\{A_i | 1 \leq i \leq c\}$ . Les sous ensembles sont définie par leurs fonctions d'appartenances, représentées dans la matrice de partition floue  $\mu = [\mu_{ik}]$  obtenue par l'algorithme GK, la  $i^{\text{ème}}$  ligne de cette matrice contient les

valeurs de la fonction d'appartenance du  $i^{\text{ème}}$  sous ensemble flou  $A_i$  de  $Z$ . la matrice de partition satisfait les conditions suivantes :

$$\mu_{ik} \in [0,1], \quad 1 \leq i \leq c, \quad 1 \leq k \leq N, \quad (4-2).$$

$$0 < \sum_{k=1}^N \mu_{ik} < N, \quad 1 \leq i \leq c. \quad (4-3).$$

$$\sum_{i=1}^c \mu_{ik} = 1, \quad 1 \leq k \leq N, \quad (4-4).$$

La 3<sup>ème</sup> expression traduit une condition de normalisation d'inspiration probabiliste, elle contraint la somme de chaque colonne à 1, et alors le total des appartenances de chaque  $Z_k$  et dans tous les classes est égal à 1, elle Signifie qu'aucun des sous ensembles flous est vide et qu'aucun contient toutes les données. La 1<sup>er</sup> expression établit le fait que les degrés d'appartenance sont des nombres réels de l'intervalle [0,1].

#### IV.4.2. Algorithme de clustering flou:

Les algorithmes de clustering flou optimisent itérativement un critère de classification afin d'établir une partition floue d'un ensemble de données en un certain nombre de classes. Le groupement des données est fait à partir d'une phase d'apprentissage en utilisant une mesure de similitude par l'intermédiaire de techniques de classification. Au niveau de la modélisation, à chaque cluster correspond théoriquement un fonctionnement homogène du système qui peut se présenter sous la forme d'un modèle linéaire local. L'algorithme de coalescence floue présenté Gustafson-Kessel (GK) qui est une extension de l'algorithme FCM, est basé sur la minimisation d'une fonction objective [37].

$$J_{GK}(Z, U, V, A) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ikA_i}^2 \quad (4-5).$$

Avec:  $A = \{A_1, A_2, \dots, A_c\}$

$Z$  : ensemble des données ;

$U = [\mu_{ik}]$  : matrice de partition floue de dimension  $c \times N$  ;

$m \in [1, \infty[$  : est un facteur qui désigne le degré de partition flou;

$V \in \mathbb{R}^{n \times c}$  : vecteur de prototypes de clusters (centres);

$V_i \in \mathbb{R}$  : centre de la  $i^{\text{ème}}$  classe,  $1 \leq i \leq c$  ;

Où la matrice de norme induite  $A_i$  est propre à chaque cluster, avec  $1 \leq i \leq c$ . Les matrices  $A_i$  sont utilisées comme variables d'optimisation dans la fonctionnelle c-means, permettant ainsi à chaque cluster d'adapter la norme de distance à la structure des données.

$$D_{ikA_i}^2 = (z_k - v_i)^T A_i (z_k - v_i) \quad (4-6).$$

Centres  $V_i$  des clusters :

$$V_i = \frac{\sum_{k=1}^N (\mu_{ik})^m z_k}{\sum_{k=1}^N (\mu_{ik})^m}, 1 \leq i \leq c \quad (4-7).$$

Le paramètre  $m$  influence sur la forme des clusters dans l'espace des données du système. Quand le facteur  $m$  s'approche de la valeur 1, la forme de la fonction d'appartenance pour chaque cluster est presque booléenne  $\mu_{ik} \in \{0,1\}$ . De l'autre côté, plus  $m$  est grand, plus la partition est floue. Quand  $m \rightarrow \infty$ , la partition devient floue au maximum, généralement ce paramètre est initialisé à une valeur entre 1,5 et 2,5. on remarque que  $V_i$  est t'exprimé comme la moyenne pondérée des données qui appartiennent à un cluster, où le facteur de pondération est associé aux degrés d'appartenance floue. La matrice de partition floue sera améliorée comme suit :

$$\begin{aligned} & - \text{ Si } D_{ikA_i}^2 \succ 0 \\ \mu_{i,k}^{(l)} &= \frac{1}{\sum_{j=1}^c (D_{i,kA_i} / D_{i,kA_j})^{2/(m-1)}} \end{aligned} \quad (4-8).$$

$$- \text{ Si non } \mu_{i,k}^{(l)} = 0 \text{ Jusqu'à } \|U(t) - U(t-1)\| < \varepsilon. \quad (4-9).$$

$U(t)$  : matrice de partition floue à l'itération  $(t)$ .

Le coefficient  $\varepsilon$  définit le seuil de convergence :  $U(t) - U(t-1) < \varepsilon$ , la valeur usuelle de  $\varepsilon$  est égale a 0.001, bien qu'une valeur de  $\varepsilon = 0.01$  convienne dans la plupart des cas. L'équation

$J_{GK}$  est la somme des carrés des distances entre chaque vecteur de données  $Z_k$  et le centre du cluster correspondant  $V_i$ . L'effet de cette distance est pondéré par le degré d'activation du cluster  $(\mu_{ik})^m$  correspondant au vecteur de données. En permettant à la matrice  $A_i$  de varier

alors que son déterminant reste fixe, cela correspond à optimiser la forme du cluster tandis que son volume reste constant. C'est pourquoi on considère l'algorithme GK comme une méthode de clustering avec une mesure adaptative de la distance. La contrainte sur le volume se traduit par l'expression:

$$|A_i| = \psi_i. \quad (4-10).$$

Nous avons la possibilité d'affecter des volumes différents pour chaque cluster par l'intermédiaire de  $\psi_i$  initialisé par défaut à la valeur 1. En utilisant la méthode des multiplicateurs de Lagrange, la minimisation du critère d'optimisation conduit à l'expression suivante :

$$A_i = (\psi_i \cdot \det(F_i))^{1/n} F_i^{-1} \quad (4-11).$$

où  $F$  est la matrice de covariance floue du  $i^{\text{ème}}$  cluster, définie par l'expression :

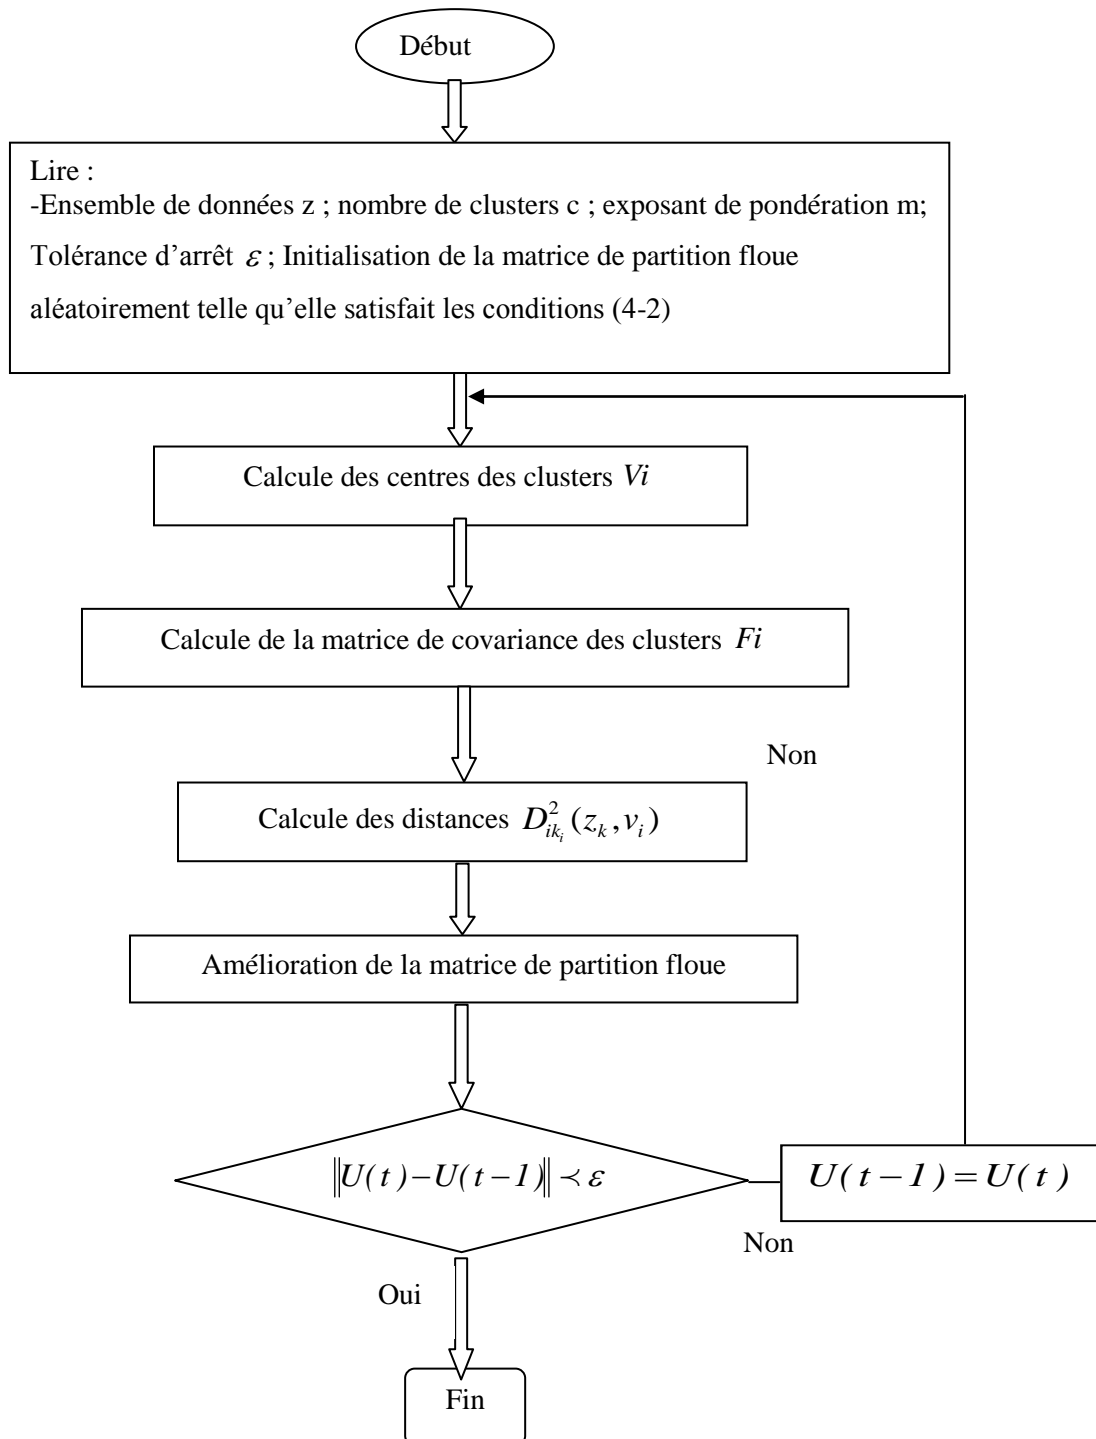
$$F_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (z_k - v_i)(z_k - v_i)^T}{\sum_{k=1}^N (\mu_{ik})^m} \quad (4-12).$$

La structure propre de la matrice de covariance floue  $F_i \in \mathfrak{R}^{n \times n}$  fournit une information sur la forme et l'orientation des clusters hyper ellipsoïdaux. En effet, la racine carrée de chacune de ses valeurs propres  $\lambda_j, j = 1, \dots, n$ , représente les longueurs des axes dans l'hyperespace. Les directions des axes sont données par les vecteurs propres  $\phi_j$ .

de (4-6) et (4-11) la mesure de distance est définie par :

$$D_{ikA_i}^2 = (z_k - v_i)^T (\psi_i \det(F_i))^{1/n} F_i^{-1} (z_k - v_i) \quad (4-13).$$

## ✓ Organigramme de l'algorithme GK :



✓ **Algorithme Gk:**

L'algorithme de clustering de GK est résumé par les étapes suivantes:

Etant donné un ensemble de vecteurs de données Z :

Fixer le nombre de clusters  $1 < c < N$

Fixer le degré  $m > 1$ , le volume  $(\psi_i)$  des clusters et la tolérance de fin de l'algorithme  $\epsilon > 0$

Initialiser la matrice de partition floue

Répéter

Pas 1. Calculer les centres de clusters

Pas 2. Calculer les matrices de covariance de cluster

Pas 3. Calculer les distances pour chaque cluster

Pas 4. Mettre à jour la matrice de partition floue Jusqu'à obtenir la stabilité de la partition.

**IV.4.3. Estimation des paramètres par les moindres carrés :**

Après avoir obtenu les sous-ensembles flous pour les antécédents il faut estimer les fonctions affines pour chaque conclusion des règles. Les paramètres  $a_i$  et  $b_i$  d'une conséquence des règles peuvent être déterminés à partir de la structure géométrique des clusters ou bien par des techniques d'estimation. Deux approches existent : Résolution d'un problème global (**GLS**) ou de  $c$ -indépendants problèmes (**C-WLS**) [7].

**a) Critère global (GLS) :**

$$j_G = \sum_{K=1}^N (y(k) - y_{est}(k))^2 \quad (4-14).$$

$y(k)$  et  $y_{est}(k)$  sont respectivement les sorties du processus réel et du processus identifié. Cette démarche peut être formulée comme la minimisation de l'erreur de prédiction totale en utilisant la formule de défuzzification (2-4) de TS, qui peut s'écrire sous forme matricielle :

$$y = x' \theta + \varepsilon \quad (4-15).$$

$\theta$  : Solution optimal de moindre carré.

$$\theta = [(x')^T x']^{-1} (x')^T y \quad (4-16).$$

Les données d'identification entrée-sortie  $Z_k = [x_k^T, y_k]^T$ , avec  $1 \leq K \leq N$ , et les degrés d'appartenance  $\mu_{ik}$  de la matrice de partition floue sont regroupés dans les matrices suivantes :

$$x = \begin{pmatrix} x_1^T \\ x_2^T \\ \cdot \\ \cdot \\ x_N^T \end{pmatrix}, y = \begin{pmatrix} y_1^T \\ y_2^T \\ \cdot \\ \cdot \\ y_N^T \end{pmatrix}, w_i = \begin{pmatrix} \mu_{i1} & 0 & \cdot & \cdot & 0 \\ 0 & \mu_{i2} & \cdot & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \mu_{iN} \end{pmatrix} \quad (4-17).$$

Afin de faciliter le calcul, la matrice de régression  $x$  est augmentée en ajoutant un vecteur colonne unitaire:

$$x_0 = [x, \mathbf{1}] \quad (4-18).$$

La matrice  $x'$  est le produit des deux matrices  $W_i$  et  $x_0$ .

$$x' = [W_1 x_0, W_2 x_0, \dots, W_K x_0] \quad (4-19).$$

Les paramètres des conséquents  $a_i$  et  $b_i$  appartenant à la règle correspondant à  $i^{\text{ème}}$  cluster sont concaténés dans un seul vecteur de paramètres  $\theta_i$ , donné par :

$$\theta = [a_1^T, b_1, a_2^T, b_2, \dots, a_K^T, b_K]^T \quad (4-20).$$

**b) Critère local (c-WLS) :**

$$J_i = \sum_{K=1}^N \mu_{ik} ( \hat{y}_{ik} - y_k ) \quad (4-21).$$

En utilisant comme facteurs de pondération des données, les degrés d'appartenance de la matrice de partition floue issus du processus de clustering. Cette approche conduit à une formulation de « **C** » problèmes indépendants de type moindres carrés pondérés dans laquelle les degrés d'appartenance expriment l'importance de la paire de données  $(x_k, y_k)$  par rapport à chaque  $i^{\text{ème}}$  sous-modèle linéaire local. La solution des moindres carrés est donnée par l'expression :

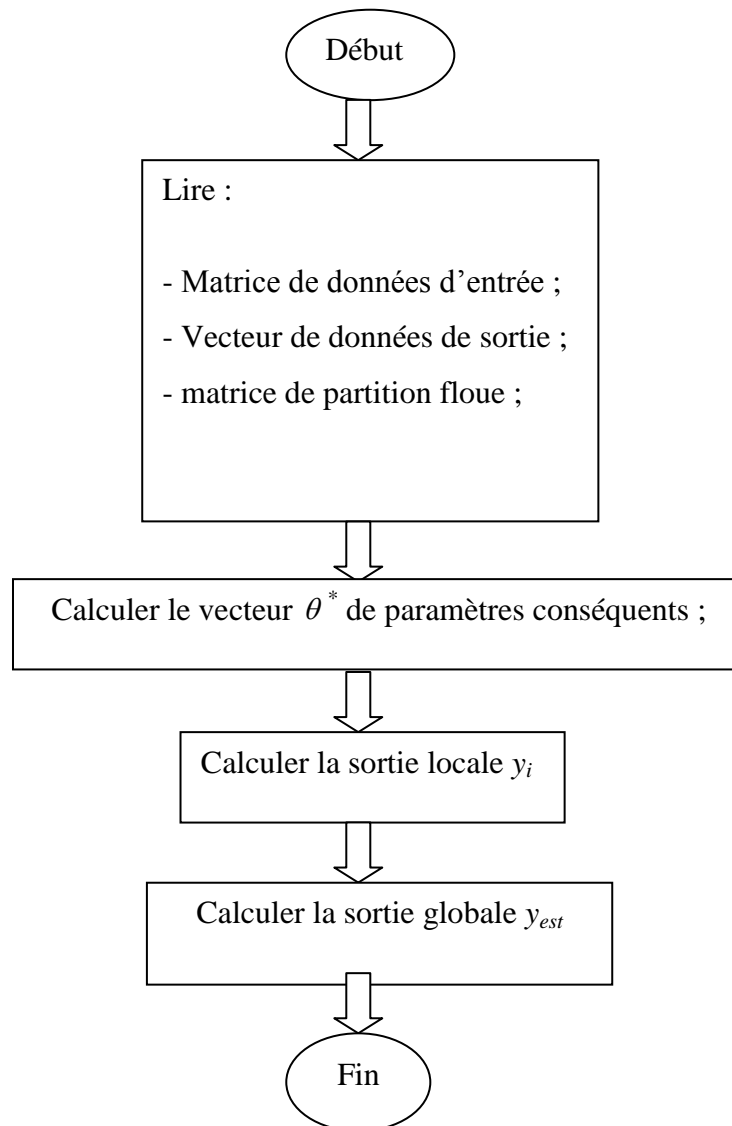
$$\theta_i = [x_0^T W_i x_0]^{-1} x_0^T W_i y \quad (4-22).$$

Les paramètres sont donnés respectivement par :

$$a_i = [\theta_1, \theta_2, \dots, \theta_p], \quad b_i = \theta_{p+1}. \quad (4-23).$$

**✓ Organigramme Sugeno Least Mean Square (SUGLMS) :**

Pour l'estimation des paramètres conséquents, on utilise l'algorithme SUGLMS dont l'organigramme est le suivant :

**IV.4.4. Validation du modèle :**

Pour évaluer la qualité de l'approximation obtenue par les modèles flous Takagi-Sugeno, nous utilisons l'erreur quadratique moyenne RMSE (Root Mean Square Error) : qui est une mesure globale sur le nombre total de points de l'écart par rapport à la valeur attendue, défini par l'expression suivante [7] [24] :

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y})^2} \quad (4-24).$$

Et la mesure VAF (Variance Accounted For) décrite par l'équation (4-28) :

$$VAF = 100\% \left[ 1 - \frac{\text{var}(y - \hat{y})}{\text{var}(y)} \right] \quad (4-25).$$

Où  $1 \leq k \leq N$  est le nombre de points considérés pour la modélisation,  $y$  est la sortie mesurée et  $\hat{y}$  est la sortie du modèle.

### IV.5. Application :

Dans le but de modéliser le comportement dynamique de l'électrovanne en appliquant les techniques de clustering flou, le système à identifier peut être représenté comme un système MIMO non linéaire autorégressive (NARX) à trois entrées ( $p_1(k)$ ,  $p_2(k)$  et  $CV(k)$ ) et deux sorties ( $X(k)$  et  $F(k)$ ), ce modèle MIMO peut être représentés de deux manières : soit la fonction non linéaire  $f_{NL}$  est une fonction vectorielle, soit le système MIMO est décomposé en plusieurs systèmes MISO [24] de type TS mais qui non pas le même type de structure au niveau de leurs règles (2-1). Dans la modélisation floue l'approche de décomposition est la plus adoptée, car cette dernière [7] peut réduire le nombre de fonctions d'appartenance et de règles. Dans ce chapitre, on c'est intéressé par la modélisation floue d'un comportement sain de l'électrovanne en s'appuyant sur les opérations suivantes :

- ✓ sélection des données et des variables ;
- ✓ classification floue des variables et définition des fonctions d'appartenance ;
- ✓ estimation des paramètres ;
- ✓ et validation du modèle.

#### IV.5.1. Sélection des données et des variables :

Nous avons généré deux jeux de données de  $N = 500$  point équidistants, issu du fichier 10.11.2001 (données réelle de l'électrovanne) [15], Les 500 premiers points sont les données d'apprentissage pour la classification et l'identification des paramètres du modèle, les deuxièmes servent de données de validation afin d'y tester la performance du modèle TS dans des divers scénarios.

### IV.5.2. Utilisation du clustering flou GK :

Le toolbox FMID «Fuzzy Modeling and Identification Toolbox for MATLAB » développé par Robert BABUSKA [39] contient une fonction principale « Fmclust » qui permet de réaliser la classification de GK et l'identification du système en un seul programme. Le Toolbox FMID travaille autour des structures suivantes dans le processus d'identification :

- La structure DAT : contient toutes les informations associées aux données (noms des variables, période d'échantillonnage, nombre de données par paquets). Les deux champs Dat.U et Dat.Y sont des tableaux de cellules contenant les matrices des données d'entrée et de sorties.
- La structure FM : contient tous les paramètres du modèle flou obtenu, elle définit entièrement un système flou (nombre d'entrées, nombre de sorties, paramètres d'initialisation et résultat de l'algorithme GK, dynamiques du système, ensembles flous créés, les fonctions conséquences des règles, la base de règle).

La plupart des mesures de validité de nombre de clusters sont conçues pour quantifier la séparation et la compacité des clusters. Néanmoins, le concept de validité de clusters est ouvert à l'interprétation et peut être formulé de façons différentes. En conséquence, plusieurs mesures de validité ont été introduites dans la littérature [40]. Chaque critère est supposé atteindre sa valeur optimale lorsque la valeur de  $\mathbf{c}$  correspond au nombre de clusters réels. Nous citerons ici le critère de Xie et Beni [41] définissent la meilleure partition comme celle qui minimise le rapport (4-28) de la compacité  $C(c)$  (4-26) à la séparabilité  $S(c)$  (4-27).

$$C(c) = \frac{1}{n} \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m d_{ikA}^2, \quad \text{où} \quad d_{ikA}^2 = \|x_k - v_i\|_A^2 \quad (4-26).$$


$$S(c) = \min_{i \neq j} \|v_j - v_i\|_A^2 \quad (4-27).$$

$$XB(c) = \frac{C(c)}{S(c)} \quad (4-28).$$


Dans notre cas, on s'est basé de manière pratique sur les erreurs RMSE et VAF pour la sélection de nombre de classes qui convient ( $c=5$ ,  $c=4$ ,  $c=3$ ). Finalement, pour chaque sortie nous avons divisé l'espace de représentation en trois clusters. Nous avons utilisé l'algorithme GK avec un indice de flou  $\mathbf{m}$  égal à **2** et une tolérance de **0.001**.

### ✚ Génération des fonctions d'appartenances :

Les fonctions d'appartenance des antécédents peuvent être obtenues en calculant les degrés d'appartenance directement dans l'espace produit des variables de l'antécédent ou à partir de la matrice de partition floue  $U$  en appliquant le mécanisme de projection sur ces variables [7]. La méthode de génération des fonctions d'appartenance qui a été adoptée est la génération par projection afin de faciliter l'interprétation du modèle par rapport aux variables des régresseurs et donc celles des prémisses par la suite. Le principe de cette méthode est de projeter pour chaque règle, les ensembles flous Multidimensionnels définis point par point dans la matrice de partition floue  $U$  sur les variables individuelles des antécédents. Dans le cas où ces variables sont les entrées utilisées pour faire le clustering, il s'agit d'une projection orthogonale des données. Un avantage de cette méthode par rapport aux fonctions d'appartenance multidimensionnelles vient du fait que les fonctions d'appartenance projetées peuvent toujours être approximées par des ensembles flous convexes. De plus, des fonctions d'appartenance asymétriques peuvent être utilisées pour refléter la partition réelle du problème de régression non linéaire considéré [7]. Nous donnons à présent les fonctions d'appartenance obtenues :



**Fig. 4.2 :** Génération des fonctions d'appartenance par projection de  $X(k+1)$ .



**Fig. 4.3** : Génération des fonctions d'appartenance par projection de  $F(k+1)$ .

Maintenant, nous allons présenter les règles obtenues pour chacune des deux sorties des modèles. La forme des règles pour la sortie  $X(k)$  est donnée par les équations suivantes :

$$R_1 : \text{Si } X(K) \text{ est } A_{11} \text{ et } CV(K) \text{ est } A_{12} \\ \text{Alors } X(K+1) = a_{11} X(K) + a_{12} CV(K) + C_1.$$

$$R_2 : \text{Si } X(K) \text{ est } A_{21} \text{ et } CV(K) \text{ est } A_{22} \\ \text{Alors } X(K+1) = a_{21} X(K) + a_{22} CV(K) + C_2.$$

$$R_3 : \text{Si } X(K) \text{ est } A_{31} \text{ et } CV(K) \text{ est } A_{32} \\ \text{Alors } X(K+1) = a_{31} X(K) + a_{32} CV(K) + C_3.$$

La forme des règles pour la sortie  $F(k)$  est donnée par les équations suivantes :

$$R_1 : \text{Si } F(K) \text{ est } A_{11} \text{ et } X(K) \text{ est } A_{12} \text{ et } \Delta P(K) \text{ est } A_{13} \\ \text{Alors } F(K+1) = a_{11} F(K) + a_{12} X(K) + a_{13} \Delta P + C_1 .$$

$$R_2 : \text{Si } F(K) \text{ est } A_{21} \text{ et } X(K) \text{ est } A_{22} \text{ et } \Delta P(k) \text{ est } A_{23} \\ \text{Alors } F(K+1) = a_{21} F(K) + a_{22} X(K) + a_{23} \Delta P(k) + C_2 .$$

$$R_3 : \text{Si } F(K) \text{ est } A_{31} \text{ et } X(K) \text{ est } A_{32} \text{ et } \Delta P(k) \text{ est } A_{33} \\ \text{Alors } F(K+1) = a_{31} F(K) + a_{32} X(K) + a_{33} \Delta P(k) + C_3 .$$

#### ✚ Estimation des paramètres :

Les paramètres des deux sorties  $F$  et  $X$  représentés dans les tableaux ci-dessous, ont été estimés par la méthode d'optimisation locale afin de privilégier la performance et l'interprétation locale des modèles par la suite.

règles	X (K)	CV (K)	biais
$R_1$	0.35288	0.15049	0.33191
$R_2$	0.70442	-0.07591	0.16511
$R_3$	1.4313	-0.050726	-0.15649

**Tableau 4.1** : Paramètres des conséquent du modèle flou TS pour  $X(K+1)$ .

règles	F (K)	X (K)	$\Delta P(K)$	biais
$R_1$	-0.29264	-1.1979	-3.2837e007	1.4324
$R_2$	1.9637	1.7923	-6.0414e-007	-0.97704
$R_3$	2.5788	3.1607	-4.9072e-007	-1.9868

**Tableau 4.2** : Paramètres des conséquent du modèle flou TS pour  $F(K+1)$ .

Les centres des classes du déplacement et du flue, sont répertoriés respectivement dans les tableaux suivants :

règles	X (K)	CV (K)
$R_1$	0.5889	0.6110
$R_2$	0.5936	0.5614
$R_3$	0.6513	0.5903

**Tableau 4.3 :** Centres des classes du modèle flou TS pour X (K+1).

règles	F (K)	X (K)	$\Delta P (K)$
$R_1$	0.46112	0.61954	9.2112e+005
$R_2$	0.45575	0.60408	9.5292e+005
$R_3$	0.43134	0.60915	9.0919e+005

**Tableau 4.4 :** Centres des classes du modèle flou TS pour F (K+1).

Les figures 4.4 et 4.5 montrent les courbes des modèles mesurés et estimés pour les deux signaux F et X respectivement.




Fig. 4.4 : Test de validation du modèle flou TS de flue.




Fig. 4.5 : Test de validation du modèle flou TS de déplacement.

### ✚ Validation du modèle :

La qualité numérique de l'approximation est mesurée en utilisant les critères RMSE et VAF. Les valeurs idéales pour ces deux critères sont respectivement 0% et 100%. La performance numérique comparative des deux approximations pour les données d'apprentissages, est regroupée dans le Tableau 4.5 :

Variables	RMSE	VAF
X (k)	0.018003	82.582 %
F (k)	0.036999	80.761 %

**Tableau 4.5 :** Performance numérique du modèle flou TS.

Afin de valider le modèle réalisé, nous le simulons sur les données de validation. Les performances du modèle sain sur les données d'apprentissage en présence de bruit et de points aberrants sont encourageantes car l'erreur commise est très faible et le modèle simulé colle aux données. Concernant les données de validation, Les résultats obtenus pour l'évaluation de l'approximation de F et X sont détaillés dans le Tableau 4.6.

	APPRENTISSAGE	VALIDATION
RMSE (F)	0.036999	0.036634
RMSE (X)	0.018003	0.020423
VAF (F)	80.761 %	75.914 %
VAF(X)	82.582 %	71.113 %

**Tableau 4.6 :** Performances globales du modèle.

**✓ Discussions :**

On remarque que les résultats obtenus pour les données d'apprentissage sont mieux par rapport aux résultats obtenus pour les données de validation, mais il n'y a pas une grande différence. D'après les figures (4.4 et 4.5) qui illustrent les courbes réelles et estimées pour les deux modèles (F et X), on peut s'apercevoir qu'il y a un dépassement considérable de l'approximation sur les régions courbes. Ce dépassement est toutefois normal, il est dû au mécanisme standard d'inférence de la sortie globale dans le modèle TS, il faut noter aussi l'effet du mécanisme de projection des fonctions d'appartenance afin d'obtenir des ensembles flous unidimensionnels sur les variables d'entrée, ce qui peut entraîner un changement de forme. En effet, dans certains cas la somme des degrés d'appartenance peut être supérieure à 1. Cela peut se traduire par des biais sur les valeurs attendues des paramètres des conséquents.

**IV.6. Conclusion :**

Le travail proposé dans ce chapitre s'articule sur les techniques de la modélisation floue, un algorithme a été présenté composé de trois étapes principales :

1. le clustering flou ;
2. la détermination des fonctions d'appartenances floues des permises ;
3. l'estimation des paramètres des conséquences du modèle TS.

Nous avons considéré la méthode de clustering floue GK, afin de générer automatiquement la décomposition à partir des données entrée-sortie du système. Ainsi, la génération des fonctions d'appartenance par projection et l'estimation des paramètres des conséquent par la méthode des moindres carrés. Finalement, nous avons évalué la qualité de l'approximation obtenue par les modèles flous TS en utilisant le calcul de l'erreur quadratique moyenne RMSE et VAF pour chaque modèle.

La modélisation floue de type TS ne fait pas intervenir une connaissance préalable des équations de la dynamique du système (seulement des données), elle permet la représentation des systèmes non linéaires statiques ou dynamiques par une concaténation de sous modèles linéaires associés aux conséquents des règles. La caractérisation d'un système non linéaire par une approche multimodèle est un chemin prometteur pour un rapprochement entre la théorie mathématique et la pratique industrielle de la commande automatique. En effet, en obtenant une représentation simple par zones d'opération définies par les fonctions d'appartenance dans les antécédents.

### Conclusion générale :

Le travail présenté dans ce mémoire a porté sur le développement d'un algorithme de diagnostic industriel FDI basés sur la logique floue, capable de détecter et d'isoler les défauts qui peuvent apparaître sur l'électrovanne pneumatique présentée par le BENSHPMARK; et la réalisation d'un modèle flou de l'électrovanne de type TS pour la simulation de défauts multiples contrairement au modèle Simulink;

La modélisation des systèmes non linéaires et dynamiques à partir des observations et la connaissance à priori est une branche importante de l'engineering et la science. Récemment la logique floue a préoccupé beaucoup de chercheurs, elle a été appliquées dans plusieurs domaines tels que : la modélisation, la classification et le diagnostique.

Pour les systèmes dits FDI, deux problèmes essentiels conditionnent la réussite du diagnostic. Pour la phase de détection, elle s'apparente à un problème de seuillage des résidus. Concernant la phase de localisation, le problème réside dans l'obtention de structures optimales de signatures de pannes. Dans les deux cas, l'homme possède par son expérience un certain savoir-faire qui lui serait bien utile d'utiliser. Une approche naturelle consiste à utiliser les systèmes à base de connaissance ou à insérer un raisonnement qualitatif dans les systèmes de diagnostic. Nous avons montré que l'utilisation de la logique floue pouvait être une alternative ou du moins une contribution efficace aux problèmes rencontrés lors de la phase de détection et de localisation. La détection est ainsi améliorée grâce à la définition de seuils flous. Quant à la localisation, la modélisation de la connaissance sur le système à l'aide de règles floues rend le diagnostic plus robuste.

Les techniques de diagnostic sont multiples et les domaines d'application sont très étendus. De nombreuses études ont déjà abouti à des solutions mais le diagnostic rapide et précis de tout système reste un des problèmes actuels. On a pu conclure, ainsi, sur l'utilité de la notion de la logique floue dans les systèmes experts de diagnostic lorsque le domaine étudié présente les caractéristiques nécessaires à l'utilisation de la logique floue, cette dernière ne peut être que bénéfique. En fait, les systèmes experts flous d'aide à la décision générés à partir de l'environnement conçu nous ont permis de dégager les points suivants :

- ✚ Ces systèmes d'aide à la décision procurent une méthode convenable pour incorporer la connaissance d'un expert humain dans un système expert en utilisant des termes qualitatifs et proches du langage de l'expertise;

- ✚ L'isolation d'un défaut avec un degré, ce qui donne plus de description sur l'état de diagnostic.
- ✚ Ils permettent, ainsi, de manipuler des informations.

### **Perspectives :**

Bien que les résultats de la modélisation obtenus sont encourageants, nous pourrions toujours continuer pour l'obtention d'un modèle plus précis globalement et plus interprétable localement, dans le but d'améliorer notre système d'aide au diagnostic. Plus précisément, dans la phase d'isolation des défauts.

Dans les futures travaux, on cherche à faire une extension de ce système d'aide au diagnostic pour :

- réduire le problème des fausses alarmes;
- réduire le problème de non détection / isolation;
- la distinction entre le changement normal du signal et une variation due à la présence d'un défaut(s);
- simulation de multiple défaut.

Plusieurs étapes du diagnostic décrite dans le chapitre trois peuvent certainement être améliorées. Par exemple, lors de la phase d'évaluation des résidus, nous pouvons multiplier les fonctions d'appartenance dans chaque zone pour avoir plus de détail sur l'état du système.

En outre, la génération des fonctions d'appartenance par projection, permet d'obtenir des modes de fonctionnement plus interprétables. Dans ce cas ci, nous aurons des modes de fonctionnements différents. On pourrait alors construire un univers du discours pour les variables de sortie avec des termes linguistiques.

- [1] L. Zadeh, “*Fuzzy Sets, Information and control*”, vol. 8, pp. 338-353, 1965.
- [2] J.B. Kiszka, M.M. Gupta, et P.N. Nikiforuk. “*Energetic stability of fuzzy dynamic systems*”. IEEE Trans. on Syst. Man Cybern. SMC-15(5) :783–792, 1985.
- [3] Witold Pedrycz, Fernando Gomide. “An introduction to fuzzy sets : Analysis and Design”. Massachusetts, 1998.
- [4] R. BABUŠKA. “*Fuzzy and neural control*”. DISC Course Lecture Notes Control, Engineering Laboratory, Faculty of Information Technology and Systems, Delft University of Technology, Delft, the Netherlands, 2001.
- [5] J.M. Kościelny. “*Application of Fuzzy Logic Fault Isolation in a Three-Tank System*”. In 14 World Congress IFAC, Beijing, China, P-7e-05-1, pp. 73-78, 1999.
- [6] J.K. George et B. Yuan. “*Fuzzy Sets and Fuzzy Logic: Theory and Applications*”. Englewood Cliffs, N.J. Prentice-Hall, 1995.
- [7] R. BABUŠKA. “*Fuzzy Modeling for Control*”. Kluwer Academic Publishers, Boston, vol. 8, pp. 7923-8154, 1998.
- [8] E.MAMDANI, “*Application of fuzzy logic to approximate reasoning using linguistic systems*”, Fuzzy Sets and Systems, vol. 26, pp. 1182-1191, 1977.
- [9] T. Takagi, M. Sugeno. “*Fuzzy identification of systems and its application to modeling and control*”. In IEEE Transactions on Systems, Man and Cybernetics, vol. 15, No 1, PP. 116-132, 1985.
- [10] L. Zadeh. “*Outline of a new approach to the analysis of complex systems and decision processes*”. In IEEE Trans. on Systems, Man, and Cybernetics, vol. 1, pp. 28-44, 1973.
- [11] S.Y. Yi, and M.J. Chung, “*Identification of fuzzy relational model and its application to control*”, Fuzzy Sets and Systems, vol. 59, pp. 25-33, 1993.
- [12] G. Zwingelstein. “*Diagnostic des défaillances : théorie et pratique pour les systèmes industriels*”. Ed. Hermes, Paris, 1995.
- [13] R. Toscano. “*Commande et diagnostic des systèmes dynamiques*”. Ed. Ellipses, 2005.
- [14] M. Bartyś, R. Patton, M. Syfert, S.Heras, J. Quevedo. “*Introduction to the DAMADICS actuator FDI benchmark study*”. Control Engineering Practice, v. 14, pp. 577-596, 2006.
- [15] <http://diag.mchtr.pw.edu.pl/damadics> .
- [16] J.M.F. Calado, F.P.N.F. Carreira, M.J.G.C. Mendes, J.M.G. Sáda Costa, M. Bartyś. “*Fault detection approach based on fuzzy qualitative reasoning applied to the DAMADICS benchmark problem*”. In 5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes - SAFEPROCESS, Washington, USA, pp. 1179–1184. 2003.

- [17] M. Z. Bartys and M. Syfert. “*Industrial applicability of FDI algorithms: an actuator benchmark study*”. In Proceedings of the 8th IEEE Int. Conf. on Methods and Models in Automation and Robotics, pages 225–230, Szczecin, Poland, September 2002.
- [18] L. Mendonça, J. Sousa and J. Sá da Costa, “*Fault Detection and Isolation of Industrial Processes Using Optimized Fuzzyn Models*”, 82 V Palade, CD Bocaniala and L Jain Eds., Computational Intelligence in Fault Diagnosis , 2006.
- [19] P. Wasiewicz, “*Specification of sugar production processes connected to the actuators intended to use for benchmark definition*”, for internal use of DAMADICS participants, Institute of Automatic Control and Robotics, Chodkiewicza 8, 02-525, Warszawa, Poland, 2002.
- [20] Wut team with cooperation with UPC, “*Benchmark Definition -Benchmark Definition File*”, ver., DAMADICS Project, 17 March 2002.
- [21] C.D. Bocănială, S. Bumbaru, “*Contributions to Artificial Intelligence Techniques Applied to Fault Diagnosis*”, Faculty of Electrical Engineering and Computer Science, University .Dunărea de jos. galăți, Romania, 2005.
- [22] M. Bartyś, M.J. Kościelny, P. Wasiewicz. “*Description of Methods of Artificial Generation of Actuator Faults for Research and Benchmarks*”. In DAMADICS Workshop, Dist-University Genova, 25-26 May 2001.
- [23] M. Bartyś, M. Syfert. “*Using Damadics Actuator Benchmark Library (DABLib)*”. In manuscript on: <http://diag.mchtr.pw.edu.pl/damadics>, ver. 2002.
- [24] R. BABUŠKA, J. A. ROUBOS, H. B. VERBRUGGEN. “*Identification of MIMO systems by input-output TS models*”. In IEEE International Conference on Fuzzy Systems, Anchorage, USA, vol. 1, pp. 657-662, 1998.
- [25] J. Zhao, R. Gorez, V. Wertz. “*Synthesis of Fuzzy Control Systems Based on Linear Takagi-Sugeno Fuzzy Models*”. In MURRAY-SMITH, R., JOHANSEN, T.A., (Eds.), Multiple Model Approaches to Modelling and Control, Taylor & Francis, London, pp. 307-336, 1997.
- [26] J.M. Koscielny, M. Syfert. “*Fuzzy diagnostic reasoning that takes into account the uncertainty of the relation between faults and symptoms*”. In Int. J. Appl. Math. Comput. Sci., Vol. 16, No. 1, pp. 27–35, Poland, 2006.
- [27] P.M. Frank, “*The application of fuzzy logic to fault diagnosis and supervision*”, LFA, pp. 59-87, 1998.

- [28] P.M. Frank. “*The application of fuzzy logic to fault diagnosis and supervision*”. LFA, pp.59-87, 1998.
- [29] N. Kiupel, P.M. Frank, “*Fuzzy supervision for lean production*”, In 6<sup>th</sup> Institute for Automation and Robotic IAR Kolloquium, Duisburg, Germany, pp. 163-176, 1992.
- [30] M. Syfert, J.M. Kościelny. “*Fuzzy neural network based diagnostic system application for three-tank system*”. European Control Conference, Porto, Portugal, 1631-1636. 2001.
- [31] M. Syfert, P. Rzepiejewski, P. Wnuk, J.M. Kościelny. “*Current diagnostics of the evaporation station*”, Institute of Automatic Control and Robotics, pp. 02-525. Warsaw, 2005,
- [32] P. Supavatanakul, J. Lunze, V. Puig, J. Quevedo. “*Diagnosis of timed automata: Theory and application to the DAMADICS actuator benchmark problem*”. Control Engineering Practice, v. 14, pp. 609–619, 2006.
- [33] M.R. Spiegel. “statistique“. ISBN : 2-10-0006515-7, Dunod, Paris, 2002.
- [34] M. Bartyś, M. Syfert. “*Data file description*”. In manuscript on: <http://diag.mchtr.pw.edu.pl/damadics>, ver. 2002.
- [35] M.bartyś, P. wasiewicz, M.syfert & j.m. Kościelny. “*progress with the industrial Actuator real data benchmark study damadics*”. In Workshop Robust methods in fault Diagnosis, Warszawa, Poland, 2002.
- [36] J.M. Kościelny, M. Bartyś, P.Rzepiejewski. “*Fuzzy Logic Application for Fault Isolation of Actuators*”. In 5-th DAMADICS Workshop on Integration of Qualitative/Quantitative Methods for Fault Diagnosis Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems, FP5 DAMADICS Project, 2004.
- [37] D.E. Gustafson, W.C. Kessel. “*Fuzzy clustering with a fuzzy covariance matrix*”. In Proceedings of the 18th IEEE Conference on Decision and Control, pages 761–766, San Diego, CA, USA, 1979.
- [38] J. S. R. Jang “*ANFIS: Adaptive network based fuzzy inference system*”, In IEEE Transactions on Systems, Man, and Cybernetics, v. 23, N 3, pp. 665-684. 1993.
- [39] R. Babuska, “*Fuzzy Modeling and Identification Toolbox for the User’s guide*”, Delft University of Technology, Delft, the Netherlands, August 1998
- [40] J. Bezdek, “*Pattern Recognition with Fuzzy Objective Function*”. Plenum Press, New York, 1981.
- [41] Xie and Beni. “*A validity measure for fuzzy clustering*”. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 13, pp. 841-847. 1991.

## Annexe A

Fault Description
-------------------

### *Control valve faults*

- f1** Valve clogging
- f2** Valve plug or valve seat sedimentation
- f3** Valve plug or valve seat erosion
- f4** Increased of valve or bushing friction
- f5** External leakage (leaky bushing, covers, terminals)
- f6** Internal leakage (valve tightness)
- f7** Medium evaporation or critical flow

### *Pneumatic servo-motor faults*

- f8** Twisted servo-motor's piston rod
- f9** Servo-motor's housing or terminals tightness
- f10** Servo-motor's diaphragm perforation
- f11** Servo-motor's spring fault

### *Positioner faults*

- f12** Electro-pneumatic transducer fault
- f13** Rod displacement sensor fault
- f14** Pressure sensor fault
- f15** Positioner feedback fault

### *General faults / external faults*

- f16** Positioner supply pressure drop
- f17** Unexpected pressure change across the valve
- f18** Fully or partly opened bypass valves
- f19** Flow rate sensor fault