

Supervision adaptative et pronostic de défaillance pour la maintenance prévisionnelle de systèmes évolutifs complexes

THÈSE

présentée et soutenue publiquement le 1^{er} décembre 2010

pour l'obtention du

Doctorat de l'Université Lille 1

(Spécialité Automatique et Informatique Industrielle)

par

Moussa Amadou TRAORÉ

Composition du jury

<i>Président :</i>	H. CHAFOUK	Professeur associé HDR à l'ESIGELEC, Rouen
<i>Rapporteurs :</i>	M. SAYED MOUCHAWEH	Professeur à l'Université de Reims
	M. COMBACAU	Professeur à l'Université de Paul Sabatier de Toulouse
<i>Examineur :</i>	V. COCQUEMPOT	Professeur à l'Université Lille 1
<i>Directeur de thèse :</i>	S. LECŒUCHE	Professeur à l'École des Mines de Douai
<i>Encadrant :</i>	E. DUVIELLA	Maître assistant à l'École des Mines de Douai

Mis en page avec la classe thloria.

Remerciements

Les travaux de recherche présentés dans ce manuscrit ont été réalisés au sein de l'Unité de Recherche en Informatique et Automatique (*URIA*) de l'École des Mines de Douai, dont je remercie les membres pour leur accueil au sein de l'unité de recherche, pour leur aide et leur sympathie.

J'adresse mes remerciements les plus sincères à mon directeur de thèse, Stéphane Lecœuche professeur des École des Mines, qui m'a suivi et guidé tout au long de ce travail et m'a ouvert la voie vers la recherche scientifique. Ses remarques et ses conseils ont permis l'accomplissement de ce travail.

J'exprime ma profonde gratitude à Eric Duviella, enseignant chercheur à l'École des Mines de Douai, non seulement pour son encadrement de très haut niveau, ses précieux conseils et orientations, mais également pour sa disponibilité et son dévouement. Je le remercie de m'avoir toujours poussé vers l'avant, pour la confiance qu'il a porté à mon égard et qui m'a permis d'acquérir une précieuse expérience du métier d'enseignant. Je le remercie pour sa sincère amitié et ses précieuses qualités humaines. Durant mes années, il a su me donner ce regard scientifique qui permet de mieux comprendre les choses aussi bien dans la vie professionnelle que privée. Je ne serais certainement pas arrivé au bout de ces années sans son soutien et son encouragement.

Je remercie messieurs les membres du jury pour l'attention qu'ils ont bien voulu apporter à ce travail.

Je tiens à exprimer ma gratitude à l'École des Mines de Douai et tout particulièrement à la direction de l'école, à la direction de la recherche et aux responsables du département informatique et automatique, qui m'ont donné les moyens matériels et techniques pour mener à bien ce doctorat.

Je souhaiterais exprimer mes sincères remerciements à mes amis Laurent Bako, enseignant chercheur à l'École des Mines de Douai, Abdelkader Akhenak et Amadou Abdoulaye Ba pour leur soutien moral, merci à vous.

Je voudrais également remercier tous les enseignants-chercheurs et les techniciens de l'École des Mines de Douai avec qui j'ai collaboré au cours de mes enseignements pour la confiance qu'ils m'ont accordé et l'expérience qu'ils m'ont fait découvrir. Je remercie très chaleureusement mon collègue de bureau Guillaume Grondin, et mes amis doctorants Lyes Hamoudi et Khaled Boukharouba. Je ne peux oublier François Corté pour sa disponibilité et sa sympathie envers moi.

Enfin, je tiens à remercier ma famille pour leur affection et leurs encouragements. Je ne peux oublier ma sœur Aissata Traoré et mon oncle Mamoudou Traoré pour leurs soutien inconditionnel durant toutes mes années d'études. Je ne serais certainement pas arrivé au bout de mes années d'études sans leurs soutien et leurs encouragement.

Je remercie Aissata Corera, pour sa patience, son soutien et son dévouement qui fut particulièrement indispensable pour arriver au bout de ces années de thèse.

Citation

On commence par le plus simple et on complique !!

*Je dédie cette thèse,
à mes parents,
à mes frères et sœurs,
à mon fils,
à la mémoire de Samba Traoré*

Table des matières

Table des figures	xii
-------------------	-----

Notations	
-----------	--

Acronymes	xvii
-----------	------

Introduction générale	1
-----------------------	---

Chapitre 1	
Maintenance prévisionnelle	5

1.1	Introduction	5
1.2	Différents types de maintenance	6
1.2.1	Maintenance corrective	6
1.2.2	Maintenance préventive	7
1.3	Maintenance prévisionnelle	8
1.4	Architecture de supervision et de pronostic	10
1.4.1	Processus de supervision	11
1.4.1.1	Modélisation	11
1.4.1.2	Module de surveillance	14
1.4.1.3	Méthodes de diagnostic	19
1.4.2	Processus de pronostic de défaillance	23
1.4.2.1	Approches de pronostic basées sur un modèle physique	25
1.4.2.2	Approches de pronostic basées sur les données de retour d'expérience	25
1.4.2.3	Approches de pronostic guidées par les données	25
1.5	Stratégie de maintenance	26
1.6	Problématique liée aux Systèmes Dynamiques Évolutifs (<i>SDE</i>)	27
1.6.1	Caractéristiques des <i>SDE</i>	27

1.6.2	Propriétés nécessaires pour la mise en œuvre d'outils de maintenance prévisionnelle des <i>SDE</i>	32
1.7	Conclusion	33

Chapitre 2	
Système de supervision adaptatif	35

2.1	Introduction	35
2.2	Principe du diagnostic par <i>RdF</i> floue	36
2.2.1	Technique de <i>RdF</i> floue	36
2.2.2	Phase d'analyse	38
2.2.2.1	Détermination de l'espace de décision flou	38
2.2.2.2	Représentativité des modes de fonctionnement	39
2.2.3	Phase d'exploitation	41
2.3	Méthodes de diagnostic adaptatif	42
2.3.1	Méthode Fuzzy Pattern Matching (<i>FPM</i>)	42
2.3.1.1	Phase d'apprentissage	43
2.3.1.2	Phase de classification	44
2.3.1.3	Procédure de détection d'une nouvelle classe par la méthode <i>FPM</i>	47
2.3.2	Méthode inspirée des <i>k</i> plus proches voisins (<i>k - ppv</i>)	50
2.3.2.1	Rejet d'ambiguïté	50
2.3.2.2	Rejet de distance	51
2.3.2.3	Classification non exclusive	52
2.3.2.4	Procédure de détection d'une nouvelle classe	54
2.3.3	Méthode <i>LAMDA</i>	55
2.3.3.1	Description de <i>LAMDA</i>	55
2.3.3.2	Procédure de détection d'une nouvelle classe	56
2.4	Classifieur <i>AUDyC</i>	58
2.4.1	Présentation générale de l'algorithme <i>AUDyC</i>	58
2.4.2	Règles d'apprentissage	60
2.4.2.1	Phase de classification	62
2.4.2.2	Phase de fusion	64
2.4.2.3	Phase d'évaluation	64
2.4.3	Procédures de création et de suivi d'évolution des classes par <i>AUDyC</i>	65
2.4.3.1	Création des classes par l'algorithme <i>AUDyC</i>	65
2.4.3.2	Suivi des classes évolutives par l'algorithme <i>AUDyC</i>	65
2.5	Conclusion	66

Chapitre 3**Pronostic de défaillance de systèmes évolutifs****69**

3.1	Introduction	69
3.2	Détection des phénomènes de dégradation	70
3.2.1	Méthode de détection des dérives rapides	70
3.2.2	Méthode de détection des dérives lentes	73
3.3	Indicateurs de dégradation	75
3.3.1	Indicateurs de dégradation basés sur les fonctions d'appartenance	75
3.3.2	Indicateurs de dégradation basés sur les distances entre les modes	76
3.3.2.1	Approche basée sur la distance Euclidienne	77
3.3.2.2	Approche basée sur la distance de Kullback-Leibler	79
3.3.3	Autre technique d'estimation de $I_{d,i}$	81
3.4	Méthodes d'analyse de défaillances	83
3.4.1	Description de la démarche	83
3.4.2	Propagation des probabilités d'occurrence des événements	84
3.4.3	Estimation de probabilités en temps réel	85
3.4.3.1	Estimation de probabilité par intervalle de temps	85
3.4.3.2	Notion de Fonction de Probabilité par Episode	85
3.4.3.3	Estimation de probabilités à partir de suivi des classes	86
3.5	Pronostic de défaillance	87
3.5.1	Pronostic par apprentissage automatique	88
3.5.1.1	Structure de la méthode <i>ANFIS</i>	88
3.5.1.2	Technique de pronostic basée sur la méthode <i>ANFIS</i>	90
3.5.2	Pronostic par analyse de tendance	92
3.6	Approches de pronostic basées sur un modèle de régression prédictif	94
3.6.1	Première approche de prédiction	95
3.6.2	Deuxième approche de prédiction	97
3.7	Conclusion	99

Chapitre 4**Application à un système de thermorégulation****101**

4.1	Introduction	101
4.2	Description du thermorégulateur	102
4.3	Formulation du problème	103
4.4	Processus de supervision du thermorégulateur	105
4.4.1	Modélisation par l'algorithme <i>AUDyC</i>	105
4.4.2	Diagnostic du thermorégulateur	107

4.4.3	Détection des dérives	108
4.4.3.1	Détection des dérives rapides	108
4.4.3.2	Détection des dérives lentes	111
4.5	Indicateurs de dégradation des composants	112
4.6	Estimation des probabilités d'occurrence de défaillance	114
4.7	Pronostic de défaillance du thermorégulateur	115
4.8	Maintenance prévisionnelle du thermorégulateur	117
4.8.1	Stratégie de mise en œuvre de la maintenance prévisionnelle	117
4.8.2	Planification d'actions de maintenance prévisionnelle	122
4.9	Conclusion	124

Conclusion générale et perspectives	127
--	------------

Conclusion générale	127
----------------------------	------------

Bibliographie	129
----------------------	------------

Table des figures

1.1	Différents types de maintenance.	6
1.2	Schéma d'un circuit électrique.	9
1.3	Arbre de défaillance du circuit électrique.	10
1.4	Architecture de maintenance prévisionnelle.	10
1.5	Modules constituant le processus de supervision.	11
1.6	Processus de génération de résidus.	14
1.7	Procédure d'extraction de signatures.	16
1.8	Test <i>CUSUM</i> , (a) - saut de moyenne, (b) - fonction de décision <i>CUSUM</i>	17
1.9	Test de Shewart.	18
1.10	Processus de diagnostic basé sur la génération de résidus.	20
1.11	Techniques de <i>RdF</i> . (a) - extraction des informations sensibles à l'état du procédé, (b) - vecteur d'observation X_k et (c) - définition de l'espace de décision.	21
1.12	Démarche de diagnostic par les techniques de <i>RdF</i>	22
1.13	Observations en rejet d'ambiguïté ou de distance.	24
1.14	Différentes approches de pronostic.	24
1.15	Modes de défaillances et maintenance associée.	26
1.16	Système de réservoir soumis aux encrassements de ses parois.	29
1.17	Étude de la dynamique de la cuve, la courbe en trait continu est le Q_s du système, la courbe donnée par le multi-modèle est confondue avec le Q_s du système et la courbe en trait discontinu est le Q_s du système après la modification de s_1 et S	29
1.18	Modélisation des modes de fonctionnement du réservoir par <i>RdF</i>	31
1.19	Différents types de dérives de fonctionnement.	31
1.20	Dérives des modes de fonctionnement : (a) - dérives rapides, (b) - dérives lentes.	32
2.1	Concept d'appartenance au sens classique et au sens flou.	37
2.2	Centroïdes de trois classes déterminées par la méthode C-moyennes floues.	39
2.3	Architecture d'un système de diagnostic adaptatif.	43
2.4	Nuages de points repartis en deux classes (mode supervisé).	43
2.5	Histogramme et densité de probabilité $p_{v,1}$ de la classe C_1	44
2.6	Histogramme et densité de possibilité $\pi_{v,1}$ de la classe C_1	45
2.7	Estimation de $\pi_{1,i}$ d'une composante $x_{k,1}$ de X_k . δ_α est le centre de la barre b_α	45

2.8	Classement de nouvelles observations dans la classe C_1	46
2.9	Histogramme et densité de probabilité d'appartenance, (a) - avant le classement et (b) - après le classement des nouvelles observations.	46
2.10	Distance $d(x_{k,v}^p, x_{k,v}^{rej})$ pour chaque C_i suivant chaque composante v , avec $D = 2$	47
2.11	Évolution des observations de la classe C_1 vers la classe C_2	49
2.12	Décroissance et croissance des f_1^e et f_2^e	49
2.13	Zones de restriction pour les différentes classes.	52
2.14	Classification en fonction : (a) - de la distance, (b) - du nombre de voisins par la règle des $k - ppv$ classique.	53
2.15	Fonction d'appartenance.	54
2.16	Représentation de la 1 ^{ère} et de la 2 ^{ème} observations rejetées ainsi que leur zone de restriction respective.	55
2.17	Architecture de réseau <i>LAMDA</i>	56
2.18	Illustration de la classification par la méthode <i>LAMDA</i> , (a) - association de X_k à C_1 , (b) - association de X_{k+1} à C_3 , (c) - création d'une nouvelle classe C_4 et (d) - association de X_{k+2} à C_4	57
2.19	Architecture du réseau <i>AUDyC</i>	59
2.20	Prototype gaussien avec sa région d'influence hyperelliptique et sa fonction d'appartenance gaussienne.	60
2.21	Processus d'apprentissage en ligne du réseau <i>AUDyC</i>	61
2.22	Création du premier neurone de la couche cachée et de la couche de sortie.	63
2.23	Exemple de deux classes constituées de deux prototypes respectivement.	63
2.24	Exemple de deux classes constituées de deux et trois prototypes respectivement.	63
2.25	Procédure de fusion, (a) - Classes en ambiguïté, (b) - fusion de la classe C_1 et C_2 , avec $n_{amb} = 1$	64
2.26	Procédure de création de classes par <i>AUDyC</i> , (a) - rejet en distance de X_k par apport à la classe C_1 , (b) - création d'une nouvelle classe C_2	65
2.27	Suivi des modes de fonctionnement par l'algorithme <i>AUDyC</i> , (a) - classe C_1 à l'instant k , (b) - classe C_1 à l'instant $k + k_1$, (c) - classe C_1 à l'instant $k + k_2$ ($k_2 > k_1$) et (d) - classe C_1 à l'instant $k + k_n$ ($k_n > k_2$).	66
3.1	Variation de pression et de débit en sortie d'un réchauffeur.	70
3.2	Dérives rapides.	71
3.3	Vitesse d'évolution des observations.	72
3.4	Technique de détection des dérives rapides d'observations.	72
3.5	Technique de détection des dérives rapides, (a) - Pas d'évolution des observations de la classe C_1 , (b) - allure de la trajectoire des vitesses, avec $\Gamma = 11$	73
3.6	Technique de détection des dérives rapides, (a) - évolution des observations de la classe C_1 , (b) - allure de la trajectoire des vitesses, avec $\Gamma = 11$	73

3.7	Fonctions d'appartenance associée aux dérives rapides, (a) - dérives rapides des observations, (b) - évolution des fonctions d'appartenance.	76
3.8	Dérives lentes des classes.	76
3.9	Illustration des dérives lentes des modes d'un fonctionnement, avec C_{n_i} , C_{e_i} et C_{d_i} respectivement la classe normale, la classe évolutive et la classe de défaillance du composant i	78
3.10	Dérives lentes, (a) - dérive lente du mode de fonctionnement d'un composant, (b) - l'indicateur de dérive $I_{d,i}$ du composant.	78
3.11	Différents types de changements possibles pour une classe évolutive.	80
3.12	Classe évolutive C_{e_i} avec différentes formes, positions et orientations.	80
3.13	Indicateurs de dégradation, (a) - dérives lentes de la classe normale et (b) - $I_{d,i}$ estimés par les trois approches, $\lambda = 0.9$	83
3.14	Exemple d'un <i>Add</i> d'un système, dont les composants sont sujets à des défaillances progressives.	84
3.15	Représentation graphique d'une <i>FPE</i>	86
3.16	Interaction entre les processus de supervision et de pronostic.	88
3.17	Architecture d' <i>ANFIS</i>	89
3.18	Approximateur <i>ANFIS</i> , (a) - Evolution de la classe normale vers la classe anormale, (b) - p^{E_i} réelle et \hat{p}^{E_i} prédite sont confondues.	92
3.19	Prédiction de l'état futur en utilisant <i>ANFIS</i>	92
3.20	Somme des erreurs de prédiction en pourcentage en fonction du degré du polynôme.	93
3.21	Approche de pronostic basée sur la technique de régression polynômiale.	94
3.22	Tendances de dégradation possible.	94
3.23	Exemple de prédiction de l'état futur.	95
3.24	Pronostic de défaillance basé sur la technique de régression, avec $h = 20$	96
3.25	Pronostic de défaillance basé sur la technique de régression, avec $h = 40$	96
3.26	Erreurs de prédiction pour deux horizons, $h = 20$ et $h = 40$	97
3.27	Pronostic de défaillance basé sur la technique de régression : (a) - prédiction sur un horizon $h = 20$ et (b) - prédiction sur un horizon $h = 40$	98
3.28	Erreurs de prédiction pour deux horizons, $h = 20$ et $h = 40$	98
3.29	Dispersion des erreurs de prédiction : (a) - pour $h = 20$ et (b) - pour $h = 40$	99
4.1	Schéma du circuit chaud du thermorégulateur.	104
4.2	Modules constituant le processus de supervision du thermorégulateur.	105
4.3	Espace de décision des composants du thermorégulateur.	107
4.4	Système réservoir.	109
4.5	Technique de détection des dérives rapides, (a) - mode de fonctionnement du système obtenu par la technique de <i>RdF</i> , (b) - trajectoire des vecteurs vitesses pour la détection des dérives rapides.	110

4.6	Détection des dérives rapides, (a) - dérives rapides de mode de fonctionnement du système, (b) - trajectoire des vecteurs vitesses.	111
4.7	Encrassement du réchauffeur, avec C_n classe normale des 3 composants confondues, et C_{d_r} , C_{d_e} et C_{d_f} respectivement les classes de défaillance du réchauffeur, de l'échangeur et du filtre.	111
4.8	Indicateurs des dérives lentes de fonctionnement basées sur les taux de dérives.	112
4.9	Dérives lentes de fonctionnement des composants du thermorégulateur.	113
4.10	Indicateurs de dégradation du réchauffeur avec différentes valeurs de λ ($\lambda = 0$, $\lambda = 0.001$ et $\lambda = 0.003$).	113
4.11	Arbre de défaillance du thermorégulateur	114
4.12	Probabilité d'occurrence de défaillance avec $\lambda=0.001$, (a) - p^{E_1} du réchauffeur, (b) - p^{E_2} de l'échangeur, (c) - p^{E_3} du <i>filtre</i> ₁ , et (d) - p^{E_6} du système.	116
4.13	Prévision de l'état futur du système à partir de son état actuel.	116
4.14	Pronostic de défaillance, (a)&(c) - p^{E_6} avec différentes valeurs de n , et $h = 20$ et $\lambda = 0.001$ fixes, p^{E_6} réelle trait continu et p^{E_6} prédite trait discontinu, et (b)&(d) - erreur de prédiction.	118
4.15	Pronostic de défaillance, (a)&(c) - p^{E_6} avec différentes valeurs de n , et $h = 40$ et $\lambda = 0.001$ fixes, p^{E_6} réelle trait continu et p^{E_6} prédite trait discontinu, et (b)&(d) - erreur de prédiction.	118
4.16	Choix du degré n du polynôme sur N observations.	119
4.17	Architecture de la maintenance prévisionnelle du thermorégulateur.	119
4.18	Matrice de criticité des risques.	120
4.19	Réseau de Petri correspondant au mode de fonctionnement du circuit chaud du thermorégulateur.	120
4.20	Stratégie de maintenance du thermorégulateur.	121
4.21	Probabilités, (a) - p^{E_6} du système, (b) - p^{E_6} du système prédite, (c) - p^{E_i} des composants du système et (d) - p^{E_6} du système avec action de maintenance, $\lambda = 0.001$	123
4.22	État des messages de synchronisation.	124

N_c	: Nombre de classes
k	: Instant courant
N_{fen}	: Largeur de la fenêtre glissante
P_j	: Prototype j
Q_e	: Débit d'entrée du réservoir
Q_s	: Débit de sortie du réservoir
S	: Section de la partie cylindrique du réservoir
S_1	: Section de la partie conique du réservoir
b_α	: Barre α
C_{n_i}	: Classe normale correspondante au mode de fonctionnement normal du composant i
C_{e_i}	: Classe évolutive correspondante au mode de fonctionnement dégradé du composant i
C_{d_i}	: Classe défailante correspondante au mode de fonctionnement anormal du composant i
$Card$: Cardinal
$d_{kl}(\cdot)$: Distance de Kullback-Leibler
$d_{eu}(\cdot)$: Distance Euclidienne
$h_{v,i}$: Nombre de barres sur la composante v de la classe i
$I_{d,i}$: Indicateur de dégradation associé à la classe évolutive i
M_{n_i}	: Centre de la classe normale C_{n_i}
M_{e_i}	: Centre de la classe évolutive C_{e_i}
M_{d_i}	: Centre de la classe défailante C_{d_i}
n_α	: Nombre de points contenus dans la barre α
$p_{v,i}(b_\alpha)$: Probabilité du centre de la barre b_α pour la composante v de la classe i
p^{E_i}	: Probabilité d'occurrence de l'événement E du composant i
\hat{p}^{E_i}	: Valeur prédite (ou estimée) de p^{E_i}
$T_{i,j}$: Taux de dérive de la classe i en direction de la classe de défaillance j
$tr(A)$: Trace de la matrice A
X_k	: Vecteur d'observation à l'instant k
X_k^{rej}	: Observation rejetée à l'instant k
$x_{k,v}$: $v^{\text{ème}}$ composante du vecteur d'observation X_k
$\mu(X_k, C_i)$: Degré d'appartenance de l'observation X_k à la classe C_i
$\mu(X_k, P_j)$: Degré d'appartenance de l'observation X_k au prototype P_j
δ_{b_α}	: Centre de la barre b_α
$\pi_{v,i}(\cdot)$: Degré de possibilité d'appartenance à la composante v de la classe i
Σ_{n_i}	: Matrice de covariance de la classe normale C_{n_i}
Σ_{e_i}	: Matrice de covariance de la classe évolutive C_{e_i}
Σ_{d_j}	: Matrice de covariance de la classe de défaillance C_{d_j}
$\alpha^i(\cdot)$: Pourcentage de la distance parcourue par C_{e_i} en direction de C_{d_i} du composant i

Acronymes

<i>AFNOR</i>	:	Association Française de NORmalisation
<i>AMDEC</i>	:	Analyse de Modes de Défaillance, de leurs Effets et de leurs Criticité
<i>AdD</i>	:	Arbre de Défaillances
<i>AUDyC</i>	:	AUto-adaptive and Dynamical Clustering
<i>ANFIS</i>	:	Adaptive Neuro-Fuzzy Inference System
<i>CBM</i>	:	Condition-Based Maintenance (Maintenance conditionnelle)
<i>EPP</i>	:	Erreur de Prédiction en Pourcentage
<i>FPM</i>	:	Fuzzy Pattern Matching
<i>FPE</i>	:	Fonction de Probabilité par Episode
<i>SDE</i>	:	Systèmes Dynamiques Évolutifs
<i>k – ppv</i>	:	k plus proches voisins
<i>LTI</i>	:	Linear Time Invariant
<i>LPV</i>	:	Linear Parameter Varying
<i>LAMDA</i>	:	Learning Algorithm for Multivariable Data Analysis
<i>NIC</i>	:	Classe Non Informative
<i>RdP</i>	:	Réseau de Petri
<i>SIMP</i>	:	Système Intégré de Maintenance Prévisionnelle

Introduction générale

Pour la plupart des systèmes industriels actuels, la majorité des processus liés à leur exploitation a vu leur performance s'accroître en raison d'une nécessité croissante de rentabilité, de productivité et de sécurité, ainsi que par l'intégration de nouvelles technologies. Ainsi, les processus dédiés à la maîtrise et à l'optimisation des systèmes durant leur fonctionnement ont bénéficié de l'apport de nouveaux outils et de nouvelles méthodes de contrôle-commande, de supervision et de maintenance. Parmi les outils les plus récents, ceux dédiés au suivi en ligne ont permis d'améliorer la maintenance des équipements par anticipation des défaillances, rendant ainsi possible une optimisation de la planification des opérations de maintenance dans le but d'éviter de coûteuses périodes d'immobilisation. La maintenance prévisionnelle des systèmes dynamiques complexes s'inscrit ainsi dans un domaine de recherche relativement récent. Elle repose sur des outils de supervision, de suivi et de pronostic de défaillance sensibles aux évolutions du procédé. En effet, les opérateurs en charge de la conduite des procédés industriels doivent être informés du changement de comportement de celui-ci par rapport au comportement nominal prévu, mais également du changement de comportement prévu sur un horizon de temps donné, de façon à pouvoir planifier et mettre en œuvre des actions préventives et/ou correctives en tenant compte, par exemple, du plan de charge du processus industriel.

La difficulté liée au déploiement d'une stratégie de maintenance prévisionnelle réside dans la complexité mais également dans le caractère évolutif des procédés industriels. En effet, l'évolution de l'état de bon fonctionnement et des performances de ces systèmes est directement liée à leurs caractéristiques propres, à leur environnement ainsi qu'à leur utilisation. Ainsi, l'accroissement de l'efficacité des stratégies de maintenance prévisionnelle nécessite une amélioration continue ainsi que la proposition de nouvelles techniques de supervision des systèmes dynamiques complexes et d'outils de pronostic qui conduisent à la prévision de l'état futur du processus. Par ailleurs, afin de renforcer la compréhension et l'anticipation des défaillances, il est utile de baser la stratégie de supervision et de pronostic de défaillance sur une modélisation précise de connaissances expertes préexistantes (*AMDEC*¹, Arbre de défaillance, etc.) lors de l'élaboration des stratégies de maintenance prévisionnelle. Cette modélisation est utile de façon à cibler les composants du système les plus sujets aux défaillances, mais également les composants les plus critiques par rapport au bon fonctionnement.

Les objectifs principaux de cette thèse consistent à améliorer des outils de supervision et

1. Analyse de Modes de Défaillance, de leurs Effets et de leur Criticité.

à développer des techniques de pronostic de défaillance pour la maintenance prévisionnelle de systèmes évolutifs complexes dans le but de proposer une nouvelle architecture de maintenance prévisionnelle. Ces outils reposent d'une part sur une modélisation précise de connaissances expertes préexistantes et d'autre part sur des processus de supervision et de pronostic de défaillance sensibles aux évolutions du procédé. La performance de ces processus repose sur l'analyse et l'estimation en temps réel de l'état de fonctionnement du procédé, de façon à fournir des indicateurs de dégradation fiables. A cela, s'ajoute la prévision de l'état futur du procédé ou de ses composants. Sur cette base, des indicateurs tels que les valeurs probabilistes issues du processus de pronostic de défaillance peuvent être exploités pour l'aide à la prise de décision lors de la tâche de planification d'actions de maintenance préventives, en particulier de la maintenance prévisionnelle.

Le manuscrit de thèse est structuré en quatre chapitres.

Chapitre 1 : Le premier chapitre a pour objet la présentation de la problématique de maintenance prévisionnelle des systèmes évolutifs. Les différents types de maintenance utilisés dans les milieux industriels, ainsi que l'intérêt de mettre en œuvre une stratégie de maintenance prévisionnelle de systèmes évolutifs sont décrits. Les outils de modélisation, de détection et de diagnostic proposés dans la littérature sont présentés, ainsi que les approches de pronostic et la méthodologie pour la mise en œuvre d'une stratégie de maintenance prévisionnelle. Finalement, les caractéristiques des outils qu'il convient de proposer pour la maintenance prévisionnelle des systèmes évolutifs complexes sont présentées.

Chapitre 2 : dans ce deuxième chapitre, nous présentons les résultats de l'état de l'art sur les méthodes de diagnostic dédiés aux systèmes dynamiques évolutifs. Ce chapitre est divisé en quatre parties. La première partie est l'introduction sur les méthodes de diagnostic adaptatif. La seconde partie détaille les techniques de Reconnaissance des Formes (*RdF*) floue. La troisième partie est consacrée au système de diagnostic par *RdF* floue. Enfin, la quatrième partie expose la méthode de classification dynamique qui sera retenue pour la conception de notre architecture de maintenance prévisionnelle

Chapitre 3 : dans ce troisième chapitre, nous présentons les approches de pronostic de défaillance que nous avons proposées pour des systèmes dynamiques évolutifs. Ces approches permettent de faire la prédiction en temps réel de l'état futur du système. Elles sont basées sur des modèles par analyse de tendance et des techniques de régression. Les approches de pronostic proposées dans ce chapitre s'appuient sur les probabilités d'occurrence des événements de l'arbre de défaillance d'un procédé. Les probabilités d'occurrence des événements de l'arbre sont déterminées en temps réel en utilisant le couplage entre l'arbre de défaillance et la méthode de classification dynamique.

Chapitre 4 : ce quatrième chapitre est dédié à la présentation de notre démarche de maintenance prévisionnelle appliquée à un système de thermorégulation. Les différents outils de supervision, de pronostic de défaillance et les techniques de maintenance proposés dans les chapitres précédents sont illustrés sur ce procédé dans des conditions d'expérimentation réelles. L'encrassement des composants du thermorégulateur est caractérisé par des dérives lentes de fonctionne-

ment qui permettent de montrer l'intérêt des outils que nous avons proposés pour la maintenance prévisionnelle des systèmes complexes évolutifs.

1

Maintenance prévisionnelle

1.1 Introduction

Des contraintes d'exploitation de plus en plus sévères, une complexité de plus en plus croissante et une continuité de service de plus en plus exigeante amènent les entreprises à un contrôle accru de l'état de leurs installations. La maintenance régulière s'impose pour répondre aux besoins des entreprises, mais elle n'est souvent pas suffisante ou applicable à l'ensemble des équipements pour des raisons économiques ou techniques. La maintenance a été longtemps jugée par les entreprises comme un poste de dépense inévitable. Aujourd'hui elle se libère de cette réputation pour être considérée comme un facteur de compétitivité jouant un rôle fondamental dans la maîtrise des risques, qu'ils soient sécuritaires, financiers ou environnementaux [47]. Selon la norme *AFNOR* [1], la maintenance est l'ensemble des actions techniques, administratives et de management durant le cycle de vie d'un système, destiné à le maintenir ou à le rétablir dans un état lui permettant d'accomplir une fonction requise. Plus récente et ambitieuse, la stratégie de maintenance prévisionnelle permet l'optimisation des actions de maintenance et leur périodicité en fonction de l'état effectif de l'équipement et des prévisions extrapolées issues de l'analyse de paramètres significatifs de la dégradation du système. La maintenance prévisionnelle permet de contrôler en toute efficacité le bon fonctionnement d'un procédé et d'éviter de coûteuses périodes d'immobilisation des équipements. La mise en œuvre d'une stratégie de maintenance prévisionnelle d'un processus industriels se traduit d'une part sur la méthode d'analyse de défaillance, et d'autre part sur le développement d'un système d'acquisition de données en continu, d'un système de supervision et d'un processus de pronostic capables de déterminer à tout instant l'état présent et futur du système. Cependant la supervision des systèmes industriels se heurte souvent

à l'évolution des caractéristiques du procédé due à la non stationnarité de celui-ci. Les systèmes non-stationnaires peuvent être décrits par des modèles à coefficients variables en fonction du temps. De nos jours, les industriels et les scientifiques cherchent à développer des outils de supervision et de pronostic de défaillance pour des systèmes non-stationnaires (systèmes évolutifs) afin de proposer une stratégie de maintenance prédictive appropriée [80, 58, 10].

Les différents types de maintenance sont décrits dans la section 1.2. Dans la section 1.3, nous présentons la maintenance prévisionnelle et les outils nécessaires pour sa mise en œuvre. Le système de supervision et le processus de pronostic de défaillance sont présentés dans la section 1.4. Ensuite, une stratégie de maintenance prévisionnelle est détaillée dans la section 1.5. Enfin, la définition et d'exemples des systèmes dynamiques évolutifs (*SDE*) sont décrits dans la section 1.6.

1.2 Différents types de maintenance

Il existe deux types de maintenance généralement utilisés dans les entreprises : la maintenance corrective et la maintenance préventive. Les différents types de maintenance en fonction de l'état du système sont illustrés sur la figure 1.1 [60]. Chaque type de maintenance et son mode d'application sont détaillés par la suite.

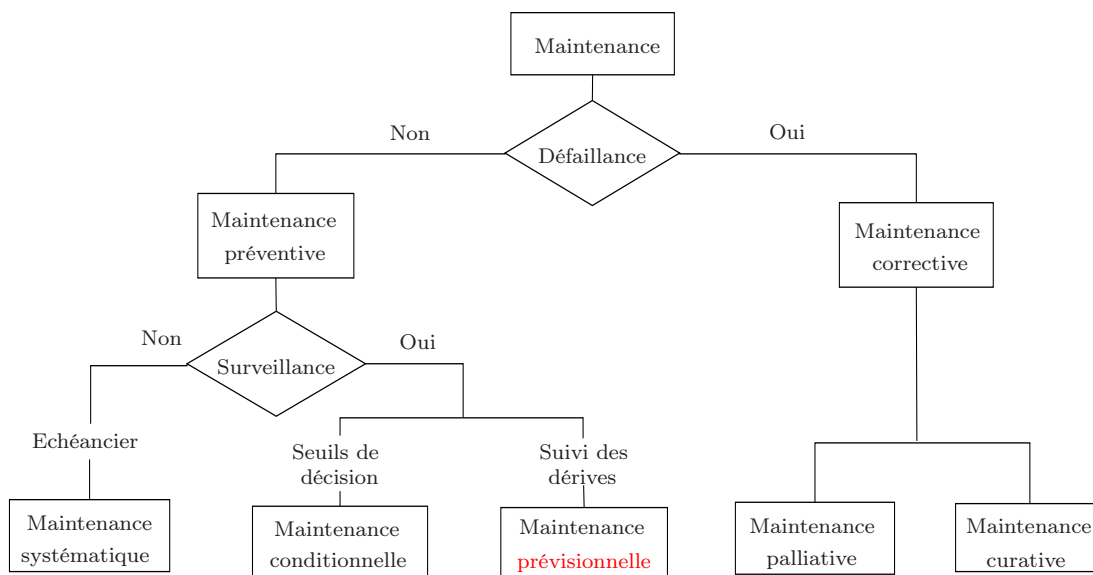


FIGURE 1.1 – Différents types de maintenance.

1.2.1 Maintenance corrective

La maintenance corrective regroupe l'ensemble des activités réalisées après la détection et la localisation d'une défaillance sur un procédé. Elle peut être palliative ou curative.

- La maintenance palliative regroupe les actions permettant à un procédé d’accomplir provisoirement tout ou partie d’une fonction requise. Elle est appelée couramment le dépannage. Ces actions de maintenance sont principalement constituées d’actions à caractère provisoire qui devront être suivies d’actions curatives [1].
- La maintenance curative a pour but de rechercher les causes initiales d’une défaillance et de réparer le ou les composant(s) défaillant(s), et ainsi d’éviter toute nouvelle occurrence de défaillance. Le résultat des activités réalisées doit présenter un caractère permanent.

Dans le cas de la maintenance corrective, l’indisponibilité du procédé est maximale et non maîtrisée. La réduction de l’indisponibilité consécutive aux défaillances dépend alors directement de l’efficacité du service de maintenance. Ce service est garant de l’état de fonctionnement du procédé industriel [1].

1.2.2 Maintenance préventive

La maintenance préventive a pour but d’améliorer la fiabilité et la disponibilité des procédés. Ainsi, elle permet de diminuer le coût de maintenance, notamment en limitant les arrêts de fonctionnement subis. La maintenance préventive comprend trois niveaux : la maintenance systématique, la maintenance conditionnelle et la maintenance prévisionnelle.

- La maintenance systématique consiste en un remplacement périodique des composants du procédé, selon les préconisations du constructeur, qu’ils soient défectueux ou non. Les inconvénients de cette maintenance périodique résident dans le fait que le composant peut tomber en panne avant l’instant critique prévu par son modèle de défaillance, ou que le composant remplacé aurait encore pu fonctionner longtemps après la date de remplacement.
- La maintenance conditionnelle s’appuie sur la mesure et l’analyse de données issues de capteurs. Elle est déclenchée lorsque les paramètres surveillés, caractéristiques des conditions de fonctionnement d’un procédé, dépassent des seuils prédéfinis.
- La maintenance prévisionnelle est subordonnée à la surveillance et à l’analyse de l’évolution des paramètres significatifs de la dégradation d’un procédé, autrement dit, l’analyse en temps réel de l’état de fonctionnement du procédé. Certains auteurs associent la dénomination de maintenance prévisionnelle à celle de maintenance prédictive [22, 40, 95]. Aujourd’hui, la maintenance prévisionnelle tend à s’affirmer comme la solution la plus performante pour répondre aux objectifs de sûreté de fonctionnement et aux contraintes liées à la compétitivité des entreprises [74].

La mise en œuvre de stratégies de maintenance prévisionnelle se justifie par la préoccupation des entreprises à rendre leurs systèmes plus fiables, plus disponibles et plus sûrs. La maintenance

prévisionnelle permet d'améliorer les performances des procédés industriels et de maîtriser les coûts de maintenance. Elle apporte également une meilleure connaissance des défaillances et des dégradations des procédés industriels pendant toute la phase d'exploitation [2]. Dans ce contexte, notre étude se limitera à la mise en œuvre d'une stratégie de maintenance prévisionnelle.

1.3 Maintenance prévisionnelle

La maintenance prévisionnelle est basée sur le suivi de l'état de fonctionnement, la détection des dégradations et la prévision de la situation future du procédé en temps réel. La connaissance de l'état futur du procédé permet d'employer au moment le plus opportun les actions de maintenance les plus appropriées. La mise en œuvre de la maintenance prévisionnelle repose généralement sur deux processus principaux : le processus de supervision et le processus de pronostic.

Dans la littérature, deux architectures de maintenance basées sur les processus de supervision et de pronostic de défaillance ont été proposées. La première intitulée Condition-Based Maintenance (*CBM*) est liée à l'état du procédé. Elle a été proposée par M. Lebold et M. Thurston [51]. Cette architecture est structurée en six modules, créant une succession linéaire de sous-processus nécessaires pour mener à bien cette maintenance [27]. La seconde architecture est un Système Intégré de Maintenance Prévisionnelle (*SIMP*) proposé par [74]. Cette architecture est constituée uniquement de trois processus : les processus de supervision, de pronostic et d'aide à la décision. En fonction de la complexité et du comportement généralement non-stationnaire des systèmes réels, ces trois processus ne permettent pas de construire systématiquement une solution optimale pour la maintenance prévisionnelle, car la modélisation en continu de l'état du système n'est pas assurée. Il est alors important de proposer une architecture dont le processus de supervision intègre un module de modélisation du procédé. Le module de modélisation a pour objectif d'établir une représentation dynamique des différents modes de fonctionnement du procédé tout en permettant leur mise à jour en temps réel. Sur cette base, les processus de supervision et de pronostic de défaillance peuvent s'appuyer sur une connaissance mise à jour des états de fonctionnement du système.

Les techniques d'analyse de défaillances utilisées sont de type *AMDE* et arbre de défaillance (*AdD*). Ces deux techniques d'analyse issues des techniques de sûreté de fonctionnement, sont couramment utilisées dans les entreprises. L'objectif de l'*AMDE* est de permettre l'identification de toutes les possibilités de défaillances critiques dans le but de pouvoir les anticiper par des interventions préventives pertinentes et ainsi les minimiser ou les éliminer le plus tôt possible. Les résultats de l'*AMDE* sont toujours présentés sous forme d'un tableau. Il est possible de renforcer l'*AMDE* par une étude de la criticité, obtenant ainsi l'*AMDEC* [46].

Après l'identification de tous les modes de défaillance, il est possible de construire un *AdD* du procédé. Celui-ci a pour but de rechercher toutes les combinaisons de défaillances qui conduisent à un événement indésirable² du procédé [72]. La technique d'analyse par *AdD* est basée sur

2. L'événement indésirable est l'événement redouté correspondant à l'indisponibilité du procédé.

une représentation graphique mettant en évidence les relations de cause à effet. Cette technique est complétée par un traitement mathématique (portes logique) qui permet la combinaison des défaillances des composants du système, ainsi, que de leur probabilité d'apparition [100, 89]. L'analyse par la technique *AdD* permet de déterminer la ou les coupe(s) minimale(s) (chemins critiques) nécessitant une attention particulière sur certains composants du procédé. Une coupe minimale est définie comme la plus petite combinaison d'événements pouvant conduire à l'événement indésirable du procédé. La démarche des méthodes d'analyse de défaillance est illustrée par l'exemple ci-dessous.

Exemple 1 La figure 1.2 représente un circuit électrique composé d'une pile électrique, de deux interrupteurs et d'une ampoule. Tout d'abord nous allons construire l'AMDE du circuit. Cette analyse consiste à définir les composants et leurs fonctions, et permet ainsi d'établir l'ensemble des modes de défaillances de chaque composant, la cause et l'effet sur le procédé (circuit). L'analyse de l'AMDE du circuit électrique est présentée dans le tableau 1.1. Cette analyse peut être renforcée par une étude de la criticité ($\text{criticité} = \text{probabilité} \times \text{gravité}$) afin d'obtenir une analyse AMDEC. La figure 1.3 représente l'arbre de défaillance du circuit électrique dont l'événement indésirable est "absence d'éclairage".




FIGURE 1.2 – Schéma d'un circuit électrique.

Composant	Fonction	Mode de défaillance	Cause	Effet
Pile	Fournir de l'énergie pour allumer l'ampoule	Pas d'énergie sur la ligne	Pile déchargée	Pas d'énergie
Interrupteurs k_1 et k_2	Laisser ou non le passage du courant	Le courant ne passe pas	Interrupteur grippé en Off	Pas de circulation du courant dans le circuit
Ampoule	Eclairer	Pas de lumière	Filament détruit ou douille mal serrée	Absence d'éclairage

TABLE 1.1 – Les résultats de l'AMDE du circuit électrique.

L'architecture de maintenance prévisionnelle de systèmes évolutifs que nous proposons dans ce manuscrit, repose d'une part, sur les méthodes d'analyse de défaillances et d'autre part, sur le processus de supervision et le processus de pronostic de défaillance (*voir* figure 1.4). Le couplage entre les méthodes d'analyse de défaillance et les processus de supervision et de pronostic permettent de proposer une stratégie de maintenance prévisionnelle efficiente permettant d'améliorer

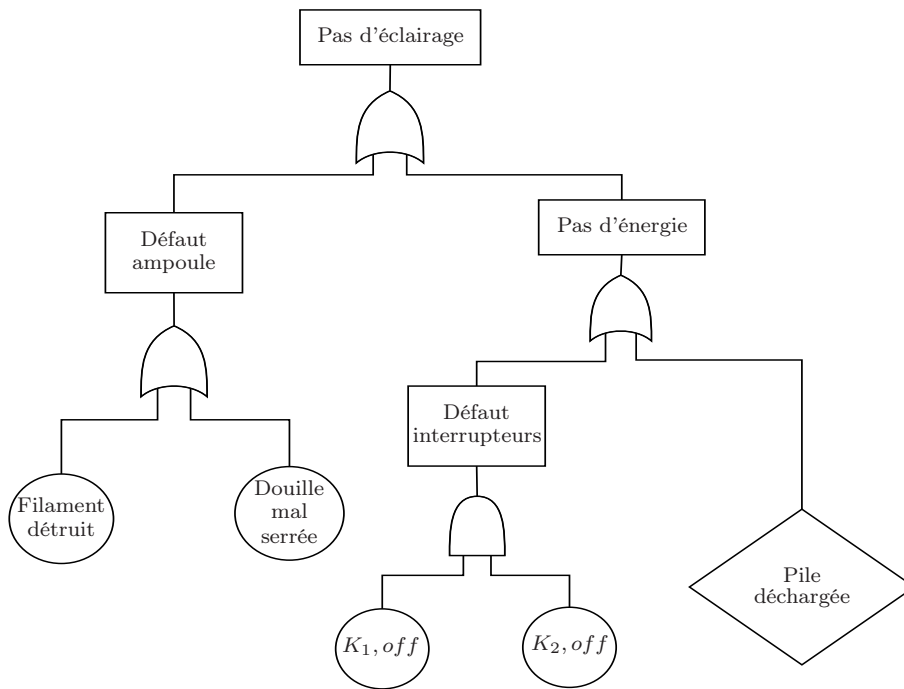


FIGURE 1.3 – Arbre de défaillance du circuit électrique.

la fiabilité et la disponibilité des procédés. Les éléments constituant le processus de supervision et de pronostic de défaillance sont détaillés dans la section suivante.

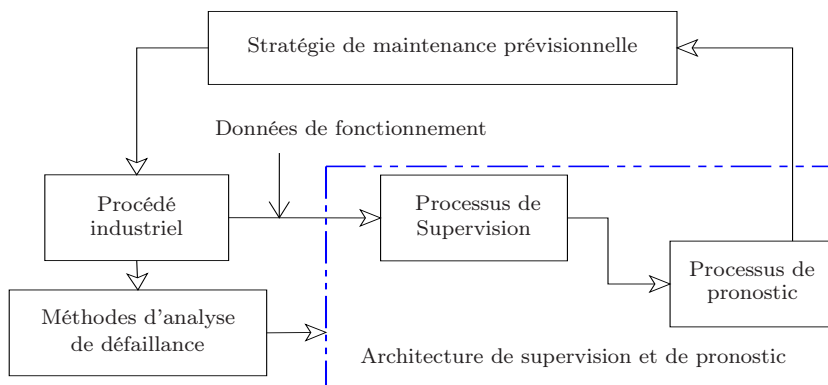


FIGURE 1.4 – Architecture de maintenance prévisionnelle.

1.4 Architecture de supervision et de pronostic

L'architecture de supervision et de pronostic de défaillance est constituée d'un ensemble de tâches relevant des domaines de modélisation, du diagnostic et de l'analyse de données. Les principales tâches seront détaillées dans cette section. La supervision a pour rôle de traiter l'ensemble des informations concernant le fonctionnement d'un procédé. Ces informations peuvent

être issues des instruments de mesure installés sur le procédé et du système contrôle-commande, pour la détection, le diagnostic et le suivi des conditions de fonctionnement liées au vieillissement des composants du procédé, ainsi qu'au changement de l'environnement [30]³. Le processus de supervision et le processus de pronostic sont deux processus complémentaires. Le processus de pronostic a pour rôle de prévoir la situation future d'un procédé après chaque détection de changement de comportement du procédé.

1.4.1 Processus de supervision

La modélisation, la surveillance (suivi et détection) et le diagnostic sont les tâches primordiales du processus de supervision d'un procédé non-stationnaire. Ces trois tâches constituent le processus de supervision, comme illustré sur la figure 1.5.




FIGURE 1.5 – Modules constituant le processus de supervision.

1.4.1.1 Modélisation

La modélisation d'un procédé est une démarche nécessaire pour la compréhension et l'analyse de la dynamique de fonctionnement d'un procédé complexe. Elle a pour objectif d'établir une représentation des différents modes de fonctionnement du procédé et d'estimer les modèles dynamiques associés à ces modes. Deux types d'approches de modélisation sont généralement proposées dans la littérature [10] :

- approche basée sur l'estimation d'un modèle analytique du procédé, en utilisant les entrées et sorties de celui-ci.
- approche basée sur l'extraction de modèles de connaissance à partir des informations pertinentes et sensibles à l'état de fonctionnement du procédé en utilisant uniquement les signaux des capteurs installés sur celui-ci.

► Approche de modélisation à base de modèles entrée-sortie

Dans le but de modéliser un procédé à partir de ses entrées et sorties, des techniques de modélisation ont été développées. Les techniques de modélisation des systèmes dynamiques sont employées en fonction des caractéristiques des systèmes mais également en fonction d'hypothèses simplificatrices. Parmi les catégories de modèles les plus usuels, nous trouvons : les systèmes linéaires, les systèmes présentant des non linéarités et les systèmes hybrides dont les systèmes à

3. <http://www.laas.fr/%7Ecombacau/SPSF/sursup.html>

commutations.

– **Systèmes dynamiques linéaires**

Les systèmes linéaires à temps invariant (systèmes *LTI*) peuvent être modélisés à partir d'une représentation d'état reliant les entrées et les sorties du procédé et déterminant les variables d'état propres à sa dynamique. Le modèle d'état d'un système *LTI* est donné par :

$$\begin{cases} \dot{x}(k) = Ax(k) + Bu(k), \\ y(k) = Cx(k) + Du(k), \end{cases} \quad (1.1)$$

où $x \in \mathbb{R}^n$ représente le vecteur d'état, $u \in \mathbb{R}^p$ le vecteur des entrées, $y \in \mathbb{R}^m$ le vecteur des sorties, avec $A \in \mathbb{R}^{n \times n}$ la matrice d'état, $B \in \mathbb{R}^{n \times p}$ la matrice de commande, $C \in \mathbb{R}^{m \times n}$ la matrice d'observation, $D \in \mathbb{R}^{m \times p}$ la matrice d'action directe et k instant courant. Pour les systèmes *LTI*, les matrices A , B , C et D sont constantes. Pour des systèmes dont la dynamique n'est pas linéaire, il est possible de considérer localement leur fonctionnement autour d'un point de fonctionnement. Sous cette hypothèse, le modèle d'état (1.1) peut être utilisé pour représenter leur dynamique.

– **Systèmes dynamiques non linéaires**

Lorsque les systèmes présentent des dynamiques non-linéaires, il est possible d'utiliser différentes approches de modélisation. La première méthode que nous présentons est l'approche de multi-modélisation qui consiste à appréhender le comportement du système par un ensemble de modèles locaux caractérisant la dynamique du procédé dans différentes zones de fonctionnement. Les multi-modèles s'écrivent sous forme d'interpolation entre plusieurs modèles *LTI*, chacun des modèles est valide dans une zone de fonctionnement. La structure la plus répandue aussi bien dans l'analyse que dans la synthèse des multi-modèles, est celle de Takagi-Sugeno [76]. Le multi-modèle de Takagi-Sugeno se présente sous la forme suivante.

$$\begin{cases} \dot{x}(k) = \sum_{i=1}^M \mu_i(\zeta(k)) \{A_i x(k) + B_i u(k)\}, \\ y(k) = \sum_{i=1}^M \mu_i(\zeta(k)) \{C_i x(k) + D_i u(k)\}, \quad i \in \{1, \dots, M\}, \end{cases} \quad (1.2)$$

où M est le nombre des sous-modèles et les matrices $A_i \in \mathbb{R}^{n \times n}$, $B_i \in \mathbb{R}^{n \times p}$, $C_i \in \mathbb{R}^{m \times n}$ $D_i \in \mathbb{R}^{m \times p}$ sont constantes et supposées connues. Les quantités $\mu_i(\zeta(k))$ représentent les fonctions de pondération qui assurent la transition entre les sous-modèles. Elles dépendent de la variable d'indexation $\zeta(k)$. Les propriétés des fonctions de pondération sont données par :

$$\begin{cases} \sum_{i=1}^M \mu_i(\zeta(k)) = 1, \quad \forall k, \\ 0 \leq \mu_i(\zeta(k)) \leq 1, \quad \forall i = 1, \dots, M, \text{ et } \forall k. \end{cases} \quad (1.3)$$

La deuxième méthode que nous présentons est l'approche *LPV* (Linéaires à Paramètres Variants). Elle permet d'identifier la dynamique des systèmes non linéaires en constituant des classes de modèles linéaires dont les paramètres dépendent d'une ou de plusieurs variables selon des conditions de fonctionnement [103]. Un modèle *LPV* est décrit par la relation suivante.

$$\begin{cases} \dot{x}(k) = A(\theta)x(k) + B(\theta)u(k), \\ y(k) = C(\theta)x(k) + D(\theta)u(k), \end{cases} \quad (1.4)$$

où les matrices A , B , C et D sont dépendantes de θ et évoluent en fonction du temps, et θ un paramètre mesurable ou estimable.

– Systèmes hybrides

Les processus industriels présentent en règle générale différents modes de fonctionnement qui sont sélectionnés, par exemple, en fonction des objectifs de production. Ces modes de fonctionnement vont, dans la majorité des cas, induire un changement de dynamique du procédé. Il est alors nécessaire de définir une catégorie de systèmes dont la dynamique est régie par des variables d'état continue mais également par des variables d'état discrète. Ces dernières, qui sont assimilées à des événements contrôlés ou non, vont provoquer des changements de dynamiques continues des procédés. Dans ce cas, nous parlerons de systèmes dynamiques hybrides. Afin de modéliser les systèmes dynamiques hybrides présentant un aspect continu et discret, différentes techniques de modélisation ont été proposées dans la littérature. Nous citerons par exemple les réseaux de Petri hybrides [42] [24], et les automates hybrides [41][107][19].

Lorsque les modèles analytiques du procédé à surveiller ne sont pas disponibles ou sont difficiles à exploiter, une approche basée sur l'utilisation directe des signaux prélevés sur le système peut être envisagée.

► Approche de modélisation utilisant des signaux de capteurs

Cette approche est très utilisée pour la modélisation des procédés industriels complexes. Un tel procédé est un système composé d'un grand nombre de composants, et présentant un nombre important d'entrées-sorties. La complexité du procédé industriel peut également résider dans la dynamique de fonctionnement de ses composants, provoquant une évolution des caractéristiques des modes de fonctionnement, en fonction des entrées et/ou des événements qu'ils subissent. Les modèles analytiques des applications industrielles sont généralement très difficiles, voire impossibles à obtenir. Une autre approche de modélisation utilisant des signaux consiste à utiliser des techniques de modélisation exploitant des signaux issus des capteurs, telles que les techniques de Reconnaissance des Formes (*RdF*). Ces techniques ont pour mission d'associer toute nouvelle mesure issue du procédé à l'un des modes de fonctionnement du système connus *a priori*. Cette méthode est basée sur l'extraction d'informations issues des mesures brutes prélevées sur le processus via des capteurs, puis sur la transformation de ces informations en modèles de connais-

sance. Ainsi, les techniques de modélisation par *RdF* ne nécessitent pas une connaissance *a priori* des modèles analytiques du procédé. En effet, la première approche de modélisation nécessite une connaissance *a priori* des modèles analytiques du procédé. La méthode de *RdF* statistique sera retenue dans la thèse pour la modélisation des modes de fonctionnement du procédé. La *RdF* statistique s'appuie sur une représentation purement numérique de formes [18].

Les informations fournies par le module de modélisation sont exploitées par le module de surveillance (suivi/détection) afin de suivre et de détecter tout changement de comportement du procédé.

1.4.1.2 Module de surveillance

Le module de surveillance permet de surveiller l'état de fonctionnement du procédé à partir des informations recueillies sur celui-ci. Ces informations sont utilisées pour détecter des changements de comportement du procédé dus à des défauts ou à des défaillances [70]. La détection consiste à décider si le procédé se trouve ou non dans l'état de fonctionnement normal. L'efficacité de la détection dépend de sa capacité à distinguer un comportement normal et un comportement anormal d'un procédé. Deux types de méthodes de détection sont généralement proposées [6] :

- méthodes de détection à base de modèles ;
- méthodes de détection sans modèle.

► Méthodes de détection à base de modèles

Les méthodes de détection avec modèle ont pour principe de comparer les mesures effectuées sur un procédé aux données fournies par le modèle du procédé [39]. Parmi ces méthodes nous trouvons les méthodes de génération des résidus. Elles visent à surveiller le procédé en comparant la réponse réelle y du procédé à la réponse \hat{y} estimée par le modèle (*voir* figure 1.6). L'écart entre les deux réponses est usuellement appelé résidu. Ces résidus sont relativement élevés lorsqu'un défaut ou une défaillance est présent dans le procédé, et sont plutôt faibles en absence de défaut ou de défaillance.

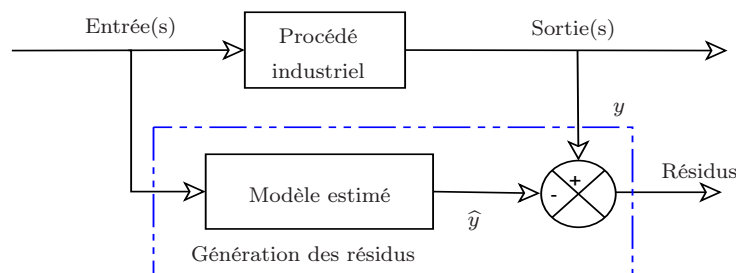


FIGURE 1.6 – Processus de génération de résidus.

Pour estimer le modèle du procédé à partir duquel sont générés les résidus, deux techniques peuvent être utilisées. Il s'agit des techniques basées sur les modèles physiques et des techniques basées sur les modèles "boîte noire". Les modèles physiques des procédés sont en général basés

sur les équations différentielles régissant leur comportement. Lorsque le modèle physique est disponible, les techniques basées sur le modèle physique sont privilégiées. Dans le cas contraire, lorsque les équations mathématiques sont trop complexes à mettre en œuvre ou que la dynamique du système est trop délicate à caractériser par des relations mathématiques, une modélisation basée sur des approches "boîte noire" offre une alternative intéressante. Les modèles boîtes noires sont construits essentiellement sur la base de mesures effectuées sur les entrées et les sorties du processus à modéliser. Les modèles boîtes noires ont pour principale caractéristique d'utiliser les données d'entrées et de sorties sans considération physique. Leur objectif est de reproduire au mieux le comportement du procédé par ajustement de paramètres d'une fonction modèle à partir des données recueillies. Cependant, les paramètres du modèle sont souvent difficilement représentatifs de paramètres physiques du procédé. L'approche "boîte noire" est détaillée plus amplement dans [50, 55, 86, 13].

Cependant, nombreuses sont les applications industrielles dont le modèle est difficile, voire impossible à obtenir à cause de la complexité du procédé. Pour ce type d'applications, les méthodes de détection sans modèle sont particulièrement bien adaptées [108].

► Méthodes de détection sans modèles

Parmi les méthodes de détection sans modèles, nous trouvons, très bien implantées dans le milieu industriel, les techniques spécifiques aux technologies de mesure rencontrées telles que l'analyse vibratoire, l'analyse thermographique, ainsi que l'analyse des lubrifiants et des particules d'usure [58]. Le principe général de l'analyse vibratoire consiste à utiliser l'information vibratoire émanant soit d'un équipement mécanique dynamique ou d'un matériel statique afin d'en déterminer son état de fonctionnement [36]. En fonction de la qualité des relevés vibratoires et de la pertinence de l'analyse, une dégradation de l'outil de production est détectée avant qu'un incident ne se produise. L'analyse thermographique permet la mesure de température au moyen d'une caméra (mesure de rayonnement) et d'un thermographe (mesure de la température). L'analyse thermographique consiste à mesurer l'intensité des émissions de rayons infrarouges d'un procédé afin d'en déterminer les conditions opératoires. Cette technique de mesure est très utilisée dans les industries chimique et métallurgique. Elle est également utilisée pour la détection de pertes de chaleur ou de fuites sur les conduits ou sur des parois de fours calorifugés. L'ensemble des techniques d'analyse des lubrifiants et d'analyse des particules d'usure est souvent repris sous la dénomination de tribologie. Ces techniques d'analyse permettent de mettre en évidence deux facteurs prépondérants dans la qualité d'un lubrifiant : sa dégradation et sa contamination [58].

Par ailleurs, des tests statistiques peuvent être utilisés plus généralement pour contrôler l'évolution d'un signal mesuré sur un procédé industriel, par exemple autour de la valeur moyenne d'un signal. Ces tests définissent généralement l'état de fonctionnement d'un procédé à l'aide de signatures, qui peuvent être obtenues par plusieurs techniques issues de l'analyse de données et du traitement de signal (*voir* figure 1.7).

Parmi les méthodes de détection basées sur les tests statistiques, nous trouvons le test du *CUSUM* (Somme Cumulée) [84], le test de *Shewart* [92] et le test du *EWMA* (Exponentially




FIGURE 1.7 – Procédure d'extraction de signatures.

Weighted Moving Averages) [105]. L'information issue du détecteur permet de décider si l'état du système est dans un mode normal ou anormal.

– **Test du CUSUM**

Soit une suite d'observations $x_v = [x_{1,v} \cdots x_{k,v}]_{v=1, \dots, D}$ issues de mesures sur un procédé, qui suivent une loi de probabilité f_θ dépendant du paramètre θ telle que :

$x_{1,v}, x_{2,v}, \dots, x_{k_{ch}-1,v}$ sont des variables aléatoires indépendantes de densité f_{θ_0} ,

$x_{k_{ch},v}, x_{k_{ch}+1,v}, \dots$ sont des variables aléatoires indépendantes de densité f_{θ_1} , avec k_{ch} instant de rupture estimé par la relation suivante.

$$k_{ch} = \inf\{k : g_k \geq h_0\}, \text{ avec } g_k \text{ la statistique de test CUSUM donnée par :} \quad (1.5)$$

$$g_k = \left(g_{k-1} + \log \frac{f_{\theta_1}(x_{k,v})}{f_{\theta_0}(x_{k,v})} \right)^+ \quad \text{où } a^+ = \max(0, a),$$

avec h_0 un seuil de détection fixé au préalable par l'expérimentateur. La statistique de test g_k peut être exprimée par la relation suivante [9] :

$$\begin{cases} g_0 = 0, \\ g_k = \max\left(0, |x_{k,v} - \bar{x}_v| - \frac{h_0}{2}\right), \end{cases} \quad (1.6)$$

où \bar{x}_v est la moyenne des $x_{k,v}$ sur N observations initialement supposées correctes.

La figure 1.8 représente une application de l'algorithme CUSUM sur un modèle gaussien.

L'idée du test CUSUM est de détecter un changement en se basant sur un rapport de vraisemblance entre deux hypothèses. La détection d'un saut revient à décider entre les deux hypothèses H_0 et H_1 :

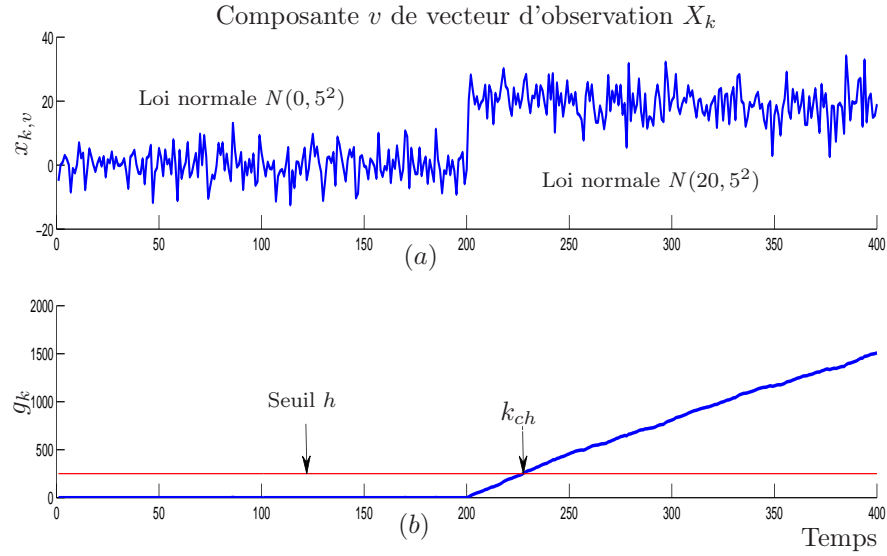
▷ $H_0 : \theta = \theta_0$, hypothèse de base, c'est-à-dire, le système est dans un état normal.

▷ $H_1 : \theta \neq \theta_0$, hypothèse alternative, c'est-à-dire, le système est dans l'état anormal.

Le logarithme du rapport de vraisemblance entre ces deux hypothèses s'écrit [36] :

$$S_k = \log \frac{f_{\theta_1}(x_{k,v})}{f_{\theta_0}(x_{k,v})}. \quad (1.7)$$

avec f_{θ_0} la densité de probabilité en se plaçant sous l'hypothèse H_0 et f_{θ_1} la densité de probabilité en se plaçant sous l'hypothèse H_1 .


 FIGURE 1.8 – Test *CUSUM*, (a) - saut de moyenne, (b) - fonction de décision *CUSUM*.

Lorsque la valeur de S_k est inférieure à 0, l'hypothèse H_0 est vérifiée ; dans le cas contraire, l'hypothèse H_1 est vérifiée. L'instant de rupture k_{ch} se caractérise par un changement de signe de S_k . Le choix entre les hypothèses H_0 et H_1 peut faire apparaître deux types d'erreurs [3] : le risque α , correspondant à la probabilité de fausse alarme, c'est-à-dire l'hypothèse H_0 est rejetée alors en réalité l'hypothèse H_0 est vraie, et le risque β , correspondant à la probabilité de non-détection, c'est-à-dire l'hypothèse H_0 est acceptée sachant que l'hypothèse H_1 est vraie. Plus de détails sur les tests d'hypothèses sont donnés dans [3, 14].

– Test de Shewart

Le test de Shewart permet de surveiller un signal dans un domaine autour d'une moyenne [16]. Il utilise deux limites fixées à partir des paramètres statistiques, moyenne et écart type du signal, pour détecter un éventuel changement. La limite supérieure L_s et la limite inférieure L_i sont définies par :

$$L_s = \bar{x}_v + \rho \sigma_v, \quad (1.8)$$

$$L_i = \bar{x}_v - \rho \sigma_v, \quad (1.9)$$

avec

$$\bar{x}_v = \frac{1}{N} \sum_{l=1}^N x_{l,v} \quad \text{et} \quad \sigma_v = \frac{1}{N} \sum_{l=1}^N (x_{l,v} - \bar{x}_v)^2.$$

Tant que le signal se situe entre les limites L_s et L_i , le système est dans la zone de fonctionnement normal ; dans le cas contraire le système est dans la zone défaillante. La figure 1.9 représente une application du test de Shewart sur N observations. Le paramètre de

contrôle ρ prend généralement deux valeurs : $\rho = 2$ pour un contrôle serré ou $\rho = 3$ pour un contrôle souple.




FIGURE 1.9 – Test de Shewart.

La règle de décision pour le test de Shewart est donnée par :

- ▷ H_0 : si $L_i < x_{k,v} < L_s$,
- ▷ H_1 : sinon.

– **Test du EWMA**

La moyenne mobile du test *EWMA* à l’instant k , notée W_k , est calculée de façon récursive par :

$$W_k = \lambda_0 x_{k,v} + (1 - \lambda_0)W_{k-1}, \quad (1.10)$$

où λ_0 est appelé facteur de pondération ou de lissage [43] et $W_1 = x_{1,v}$ la valeur initiale, avec $x_{1,v}$ la composante v de la première observation X_1 . Le test du *EWMA* permet de surveiller la moyenne mobile des observations entre deux limites L_{sEWMA} et L_{iEWMA} . Les limites supérieures L_{sEWMA} et inférieures L_{iEWMA} utilisées sont :

$$L_{sEWMA} = \mu_{EWMA} + K \sigma_{EWMA}, \quad (1.11)$$

$$L_{iEWMA} = \mu_{EWMA} - K \sigma_{EWMA}, \quad (1.12)$$

où μ_{EWMA} est la moyenne des W_k initialement supposée correcte, avec

$$\mu_{EWMA} = \frac{1}{N} \sum_{k=1}^N W_k; \text{ et } \sigma_{EWMA} = \sigma_v \sqrt{\frac{\lambda_0}{2 - \lambda_0}}, \text{ avec } \sigma_v = \frac{1}{N} \sum_{l=1}^N (x_{l,v} - \bar{x}_v)^2.$$

Le test du *EWMA* accorde aux observations, un poids qui diminue de manière exponentielle en fonction de leur ancienneté. Pour le test *EWMA*, les observations récentes ont plus d’influence sur le test de détection que les anciennes observations.

Le principal inconvénient de ces tests (*CUSUM*, *Shewart*, *EWMA*) est qu’ils ne peuvent suivre qu’une seule variable à la fois. Sur le même principe que ces tests, il est possible de

prendre en compte non plus une mais plusieurs variables grâce aux tests *MCUSUM* (Multivariate *CUSUM*) et *MEWMA* (Multivariate *EWMA*) [102]. Ces tests donnent de bons résultats sur des données stationnaires [15]. Dans le cas des systèmes non-stationnaires, une mise à jour régulière des seuils de détections devient indispensable. Cela limite donc l'utilisation de ces méthodes pour les données stationnaires.

La détection est une étape préliminaire avant d'envisager le diagnostic. Le fait de savoir qu'un changement est apparu dans le procédé ne permet pas de savoir quelle est la nature de ce changement. Ceci va être le rôle du module de diagnostic qui permet de déterminer dans quel état de fonctionnement le procédé évolue. Il a pour objectif d'établir un lien de cause à effet entre un symptôme observé et la défaillance qui est survenue.

1.4.1.3 Méthodes de diagnostic

Les méthodes de diagnostic consistent à identifier ou à localiser l'origine des défauts ou des défaillances détectés sur le procédé [18]. Dans la littérature, différentes méthodes de diagnostic ont été développées [31] :

1. les méthodes à base de connaissances ;
2. les méthodes internes ;
3. les méthodes externes.

Le choix de l'une de ces méthodes dépend du type de représentation de la connaissance. Lorsque les observations sont de type symbolique, les méthodes à base de connaissances sont les plus adaptées. Lorsqu'un modèle analytique du procédé est disponible, les méthodes internes sont privilégiées. En revanche si le modèle analytique du procédé est indisponible ou si la complexité du procédé le rend inexploitable, les méthodes externes offrent une alternative intéressante. Les différentes méthodes de diagnostic sont présentées par la suite.

– Méthodes à base de connaissances

Le diagnostic à partir de méthodes à base de connaissances est utilisé lorsqu'une connaissance humaine sur le procédé est disponible. En effet, cette méthode exploite les connaissances qualitatives que les experts du procédé détiennent. Parmi les méthodes à base de connaissances, nous citons les systèmes experts qui sont des approches faisant appel à l'intelligence artificielle [25, 102]. Actuellement, beaucoup de procédés industriels avec un nombre d'entrées/sorties restreint utilisent des systèmes experts afin d'assurer une maintenance optimale. Un système expert qui a pour but d'imiter le raisonnement humain, comporte trois éléments : la base de connaissances, le moteur d'inférence et l'interface avec l'utilisateur [31]. La base de connaissances et le moteur d'inférence sont conçus à partir du savoir des experts avant d'être intégrés à un programme donné. La base de connaissances est composée d'une base de faits et d'une base de règles : la base de faits regroupe toutes les observations faites sur le système à diagnostiquer et la base de règles contient les lois

qui associent les faits entre eux. Le moteur d'inférence est un outil informatique développé de façon à raisonner et à tirer des conclusions à partir de la description d'un problème donné, en utilisant la base de connaissances. L'interface utilisateur permet aux opérateurs de consulter le système expert. Ils peuvent ainsi vérifier et également mettre à jour leurs connaissances.

– **Méthodes internes**

Par opposition aux méthodes à base de connaissances, les méthodes internes exploitent les modèles physiques ou modèles entrées/sorties des procédés pour réaliser un diagnostic. Les méthodes internes consistent à analyser un certain nombre de valeurs numériques issues du modèle analytique du procédé et à les comparer à des données mesurées sur celui-ci. La principale méthode utilisée pour obtenir des valeurs numériques est la méthode de génération de résidus, comme illustré sur la figure 1.10. Les résidus peuvent être générés en utilisant le modèle physique, mais également les modèles "boîte noire" du procédé. La première phase de diagnostic par génération de résidus consiste à déterminer des grandeurs sensibles aux défauts et la seconde phase consiste à analyser ces grandeurs afin d'identifier et de localiser les défauts ou les défaillances détectées sur le procédé [28, 83, 31].

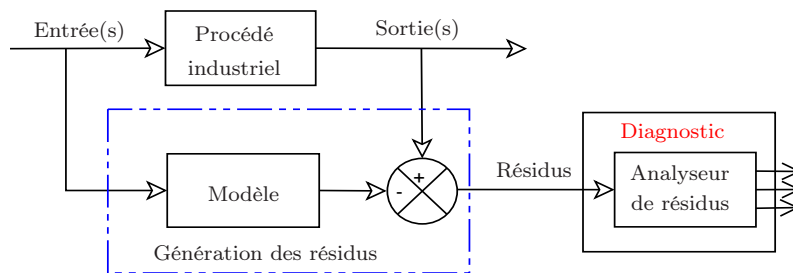


FIGURE 1.10 – Processus de diagnostic basé sur la génération de résidus.

Lorsque le modèle physique du procédé est inexistant ou difficile à obtenir, les méthodes externes peuvent être utilisées.

– **Méthodes externes**

Le système de diagnostic par les méthodes externes est très répandu dans les applications industrielles, à cause, entre autres, de la difficulté liée à l'obtention de modèles physiques du procédé ou de ses composants. Les méthodes externes qui ne nécessitent pas de modèle physique du procédé sont particulièrement bien adaptées lorsque les seules informations disponibles sont les signaux issus des capteurs positionnés sur le procédé. Elles minimisent donc la connaissance *a priori* sur le procédé à surveiller. Les méthodes externes reposent uniquement sur l'analyse de données issues du procédé, que ce soit dans un historique ou en temps réel. Ces données sont souvent regroupées sous l'appellation vecteur d'observations. La procédure de diagnostic consiste à analyser un certain nombre de caractéristiques extraites du procédé, et à les associer à un mode de fonctionnement du procédé industriel.

Parmi les méthodes externes, nous trouvons les méthodes de diagnostic par *RdF*. Le diagnostic par *RdF* est privilégié pour des procédés complexes tels que les procédés chimique, biochimique, énergétique, etc. De nombreux travaux ont permis de montrer l'intérêt de ce type de techniques [80, 85]. Elles permettent de modéliser chaque mode de fonctionnement du procédé par une classe dans un espace de représentation [58]. Une classe est définie par un regroupement des observations selon leur similarité. La détermination des classes dans l'espace de représentation permet de définir l'espace de décision (voir figure 1.11.c). Les classes sont obtenues par des techniques d'apprentissage et de classification utilisant un historique de données du procédé. L'affectation ou non d'une nouvelle observation X_k à l'une des classes indique une opération de classement ou de discrimination.

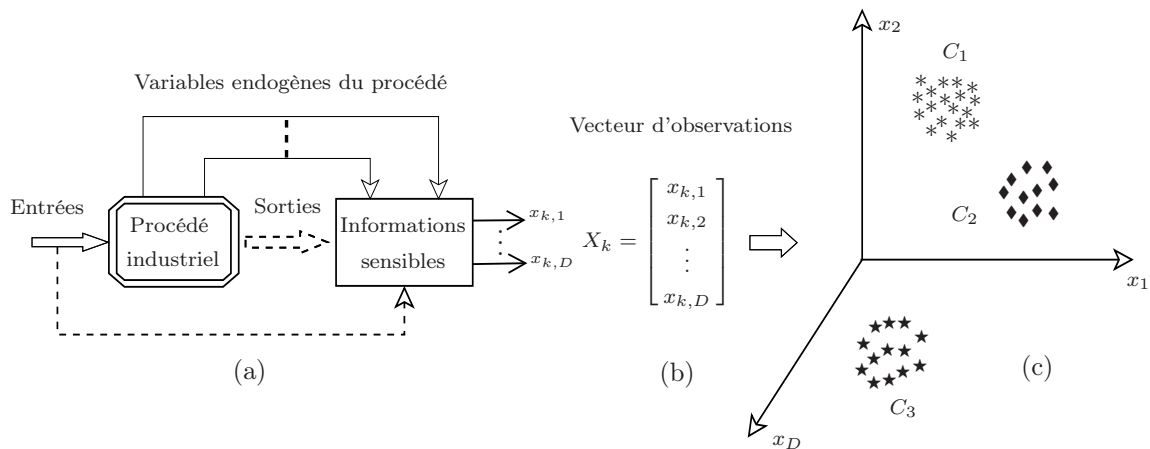


FIGURE 1.11 – Techniques de *RdF*. (a) - extraction des informations sensibles à l'état du procédé, (b) - vecteur d'observation X_k et (c) - définition de l'espace de décision.

► Diagnostic par les techniques de *RdF*

Le processus de diagnostic par *RdF* est décomposé en deux phases importantes : une phase d'analyse et une phase d'exploitation. La figure 1.12 illustre la démarche à suivre pour la conception d'un processus de diagnostic par *RdF*.

► Phase d'analyse

Dans cette phase, il s'agit d'étudier les informations fournies par les différents capteurs, les historiques ainsi que l'expérience des opérateurs, afin de définir l'espace de représentation, de construire l'espace de décision du procédé et d'extraire les règles de décision. Les règles de décision permettront d'affecter ou non une nouvelle observation X_k à l'une des classes connues.

– Espace de représentation.

Après la phase de pré-traitement, le vecteur d'observation $X_k = [x_{k,1} \dots x_{k,D}]^T$ est construit. Il est constitué des paramètres sensibles à l'état de fonctionnement du procédé. La dimension de l'espace de représentation correspond à la dimension du vecteur d'observation X_k . Les performances d'un processus de diagnostic dépendront de la pertinence des composantes constituant le vecteur d'observation X_k . Toutefois, il est important de signa-

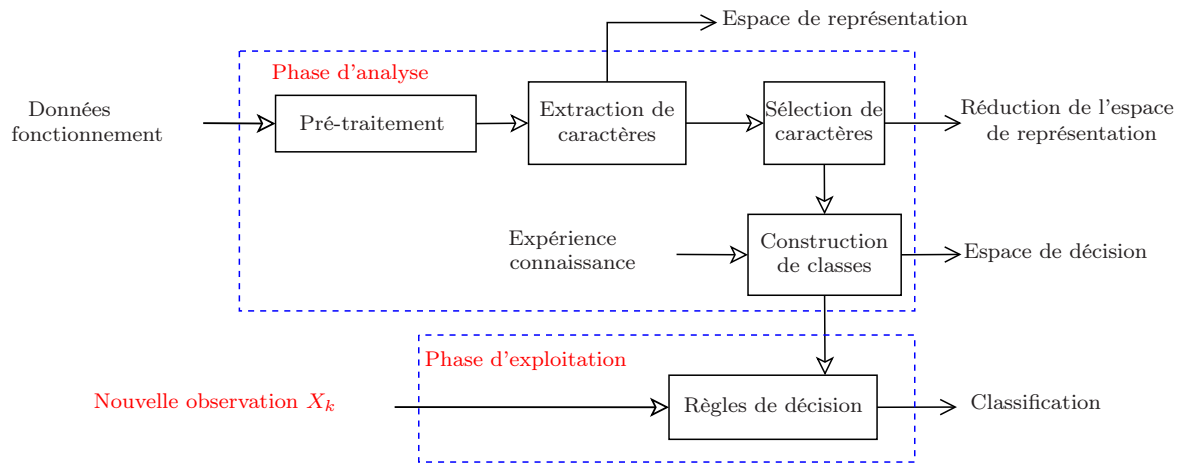


FIGURE 1.12 – Démarche de diagnostic par les techniques de *RdF*.

ler qu'un nombre important de paramètres peut être pénalisant en termes de temps de calcul. En effet, tous les paramètres calculés et constituant le vecteur d'observation initial ne seront pas forcément pertinents vis-à-vis des modes de fonctionnement du procédé. Il est donc nécessaire d'utiliser des méthodes permettant de réduire la dimension de l'espace de représentation en ne conservant que les paramètres les plus représentatifs et les plus sensibles aux évolutions de la dynamique interne du procédé. La réduction de l'espace de représentation peut être effectuée soit par la méthode d'extraction de paramètres, soit par la méthode de sélection des paramètres. La méthode d'extraction et la méthode de sélection sont détaillées plus amplement dans [97]. La méthode de sélection des paramètres présente un double avantage. En effet, elle permet de réduire non seulement la dimension de l'espace de représentation mais également le nombre de paramètres de représentation du système [80].

– **Espace de décision.**

La détermination de l'espace de décision consiste à partitionner l'ensemble d'apprentissage en un ensemble de N_c classes, c'est-à-dire de déterminer les régions de l'espace \mathbb{R}^D représentatives des différents modes de fonctionnement du système. Soit $\mathbb{X} = \{X_1, X_2, \dots, X_N\}$ un ensemble de N observations recueillies sur le procédé, avec $X_k = [x_{k,1} \ \dots \ x_{k,D}]^\top$. L'objectif est de structurer les N échantillons en classes correspondant aux différents modes de fonctionnement du procédé industriel. Dans la littérature, il existe deux types d'approches permettant d'obtenir des frontières de décision entre les différents modes de fonctionnement : approche analytique et approche statistique [58, 80]. Une phase de validation de ces classes est nécessaire. La phase de validation peut être faite soit par un expert du système, soit par des critères de validité de la partition [45]. Lorsque la classe correspondant à chaque observation est connue *a priori*, l'apprentissage peut être effectuée **en mode supervisé** (classification supervisée) [18]. Malheureusement, il n'est pas toujours possible de disposer *a priori* des connaissances sur les modes de fonctionnement de chaque observation de la

base d'apprentissage. Dans ce cas, le processus de diagnostic doit mettre en évidence une structure de classes dans un ensemble d'observations pour lesquelles aucune information quant à leur appartenance aux modes de fonctionnement n'est disponible. Il s'agit alors d'un apprentissage en mode **non supervisé** (classification non supervisée ou automatique). Lors de l'apprentissage non supervisé, il est important de noter que la labellisation des classes en termes de modes de fonctionnement reste très délicate, mais indispensable au processus de diagnostic. Cette tâche est généralement réalisée par un expert du système. Par ailleurs, il est possible de ne disposer que d'informations partielles sur les données d'apprentissage. Dans ce cas, la classification est faite en mode **semi-supervisé**. L'avantage de l'apprentissage semi-supervisé réside dans le fait que les deux types d'apprentissages supervisé et non supervisé cohabitent et se complètent [17].

► Phase d'exploitation

La phase d'exploitation permet d'affecter chaque nouvelle observation X_k recueillie sur le système à l'une des N_c classes connues de la base de connaissance. La fonction de décision (ou degré d'appartenance), notée $\hat{\mu}$ permet d'affecter une nouvelle observation à l'une des classes contenues dans l'espace de représentation (1.13). Elle permet de définir une partition de l'espace de représentation en autant de régions que de modes de fonctionnement.

$$\begin{aligned} \hat{\mu} : \mathbb{R}^D &\rightarrow \{1, \dots, N_c\} \\ X_k &\mapsto \hat{\mu}(X_k) \end{aligned} \quad , \quad X_k \in C_i \text{ si } \hat{\mu}(X_k) = i. \quad (1.13)$$

L'affectation de la nouvelle observation X_k à l'une des N_c classes conduit à la détermination du mode de fonctionnement courant du système. Il est possible qu'une nouvelle observation à classer appartienne à au moins deux modes de fonctionnement ou qu'elle se situe dans une région de l'espace de représentation très éloignée de toutes les classes connues de la base de connaissance (*voir* figure 1.13). Dans ces deux cas, l'affectation de X_k à l'une des N_c classes connues peut induire une erreur de diagnostic. Il peut alors s'avérer préférable d'affecter l'observation à une classe dite classe de rejet. Nous parlons alors de règles de décision avec rejet [18]. Il existe deux grandes notions de rejet : le rejet en ambiguïté et le rejet en distance (*voir* figure 1.13) [80, 48].

Dans ce manuscrit, nous avons présenté des outils capables d'évaluer et de diagnostiquer en continu l'état de fonctionnement d'un procédé. Cette connaissance en temps réel de l'état de fonctionnement du procédé est exploitée par le processus de pronostic afin de prévoir l'état futur du procédé ou de ses composants. La définition pronostic et les différentes approches de pronostic de défaillance sont présentées dans le paragraphe suivant.

1.4.2 Processus de pronostic de défaillance

Le pronostic de défaillance est un domaine de recherche relativement récent auquel la communauté scientifique accorde une importance croissante [62]. Dans la littérature, il y a plusieurs

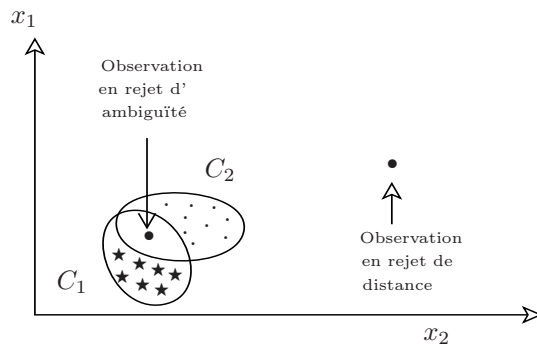


FIGURE 1.13 – Observations en rejet d’ambiguïté ou de distance.

définitions qui se rapportent au pronostic [34, 87, 56, 57, 96, 4], mais deux d’entre elles reviennent principalement :

1. le pronostic de défaillance est l’estimation ou la prédiction de la durée de vie résiduelle appelée *RUL* (Remaining Useful Life) d’un procédé ou de ses composants, c’est-à-dire la durée au bout de laquelle le composant ou le procédé ne pourra plus exercer sa fonction avec succès [57, 38].
2. le pronostic de défaillance consiste à estimer la probabilité qu’une défaillance survienne à un instant futur donné [20].

Les approches de pronostic de défaillances peuvent être réparties en trois principales catégories comme illustré sur la figure 1.14 [21]. L’approche de pronostic doit être sélectionnée en fonction des modèles et des connaissances disponibles sur un système donné. Les trois approches seront décrites dans les paragraphes suivants.

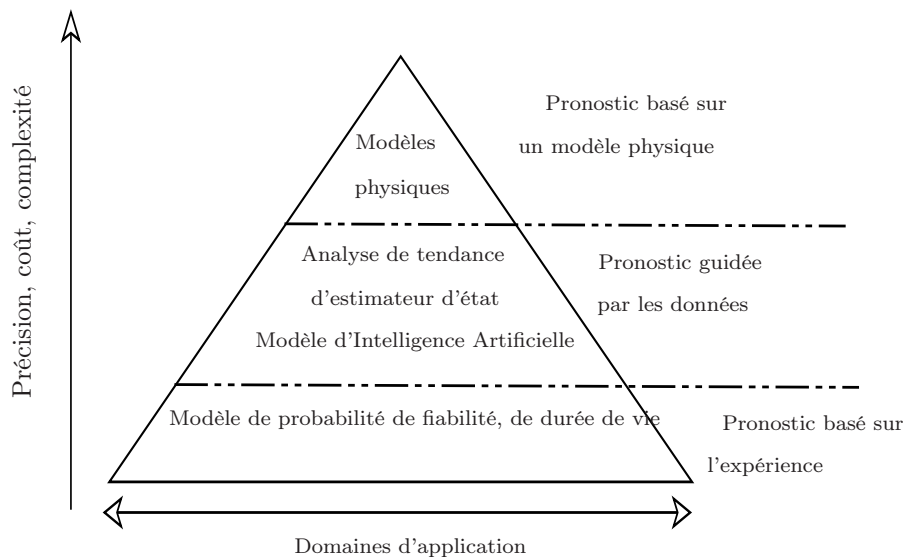


FIGURE 1.14 – Différentes approches de pronostic.

1.4.2.1 Approches de pronostic basées sur un modèle physique

Ces approches exploitent un modèle physique de la dégradation du procédé. Elles conduisent à des résultats précis, à condition de disposer d'un modèle physique fiable et réaliste de la dégradation.

Les modèles physiques de dégradation obtenus peuvent être utilisés pour évaluer la durée de vie restante du procédé en fonction de ses propriétés physiques et les équations déterministes des modes de défaillance [56]. Chaque discipline scientifique possède ses propres mécanismes de dégradation et donc ses propres modèles.

1.4.2.2 Approches de pronostic basées sur les données de retour d'expérience

Les approches de pronostic basées sur les données de retour d'expérience sont fondées sur la formalisation des mécanismes physiques de détérioration des composants. Les lois de dégradation peuvent être obtenues par modèles stochastiques initiés par connaissances *a priori* et jugement d'expert, ou par l'exploitation d'une fonction de fiabilité, notée $R(k)$. L'approche de pronostic basée sur l'expérience n'est mise en œuvre que lorsque le modèle physique de la dégradation est inconnu ou trop complexe ou lorsqu'aucun dispositif de surveillance de l'état de dégradation du système n'est opérationnel. Les techniques utilisées sont basées généralement sur des modèles de vie accélérée (*ALM* : Accelerated Life Model), des modèles à risques proportionnels (*PHM* : Proportion Hazard Model) ou la méthode de Monte Carlo [101, 91]. Les approches de pronostic exploitant des données issues du procédé sont détaillées dans le paragraphe suivant.

1.4.2.3 Approches de pronostic guidées par les données

Ces approches exploitent des informations fournies par le processus de supervision capable d'évaluer de manière continue le niveau de dégradation d'un système [91, 87]. Elles sont basées généralement sur l'utilisation des réseaux de neurones flous ou de techniques d'analyse de tendance. Certains auteurs associent la dénomination de l'approche de pronostic guidée par les données au diagnostic prédictif [68, 80]. Le diagnostic prédictif consiste à identifier l'origine d'une dégradation, puis à mettre en œuvre une technique de prévision de l'état futur du procédé [71, 108, 81]. Les approches de pronostic guidées par les données sont en plein développement. Elles reposent sur l'exploitation des indicateurs de dégradation et l'estimation de l'état futur du procédé. La connaissance en temps l'état futur d'un procédé permet la prise de décision et la planification des actions de maintenance prévisionnelle. Les approches de pronostic guidé par les données feront l'objet du chapitre 3.

Les processus de supervision et de pronostic de défaillance à eux seuls, sont insuffisants pour décider de la meilleure action de maintenance à entreprendre. Une stratégie de maintenance conduit à l'élaboration de l'ensemble des plans⁴ de maintenance permettant d'améliorer ou de

4. Le plan de maintenance regroupe l'ensemble des interventions correctives ou préventives.

rétablir l'état et les performances du procédé industriel, à partir des informations fournies par le processus de supervision et/ou processus de pronostic.

1.5 Stratégie de maintenance

Une stratégie de maintenance prévisionnelle permet de contrôler en toute efficacité le bon fonctionnement d'un procédé et d'éviter de coûteuses périodes d'immobilisation des installations. Pour y parvenir, elle doit prendre en compte les contraintes de production, les ressources humaines et matérielles disponibles, ainsi que l'ensemble des coûts associés, en collaboration avec le secteur décisionnel de l'entreprise. Cela permet de déterminer quel équipement peut subir un type d'action de maintenance et à quel moment à partir de la situation courante [74]. Dans le contexte spécifique de la maintenance prévisionnelle, le processus de supervision et/ou processus de pronostic fournissent des indicateurs permettant l'orientation, l'anticipation et le choix des actions de maintenance. La recherche des meilleures actions de maintenance intervient dès que le module de détection détecte une dégradation significative de la performance globale du procédé industriel, ou lorsque le processus de pronostic tend à mettre en évidence l'occurrence d'une défaillance sur un horizon de temps futur.

Deux types de défaillances peuvent être considérés : des défaillances progressives (défaillance par dérive) et des défaillances catalectiques [60]. Ces deux types de défaillance sont illustrés sur la figure 1.15. Les défaillances catalectiques sont complètes et soudaines, il est alors nécessaire de recourir à des actions de maintenance corrective qui impliquent généralement des temps d'indisponibilité importants.

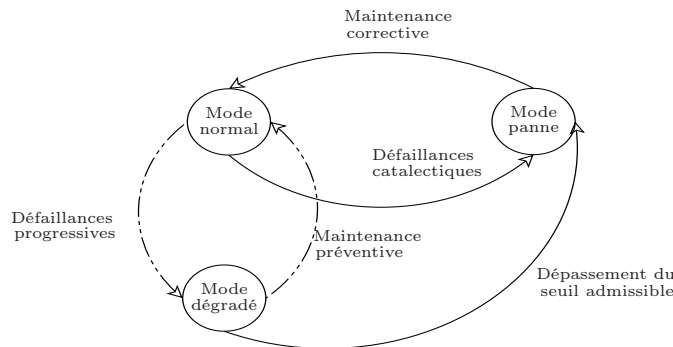


FIGURE 1.15 – Modes de défaillances et maintenance associée.

Les composants soumis à des défaillances progressives sont caractérisés par trois modes de fonctionnement : mode de fonctionnement normal, mode de fonctionnement dégradé et mode de fonctionnement panne. Lorsque le fonctionnement du composant est dans l'état de fonctionnement dégradé, une action de maintenance préventive est nécessaire pour revenir dans le mode de fonctionnement normal. La maintenance prévisionnelle a pour objectif de planifier des actions de maintenance en suivant au plus près l'état de dégradation des équipements tout en évitant l'occurrence de défaillances catalectiques. Pour pouvoir décider de l'action de maintenance la

plus appropriée en fonction de la stratégie de maintenance, la disponibilité des équipements et de l'état de dégradation, nous utilisons une modélisation basée sur les Réseaux de Petri (*RdP*). Le franchissement des transitions du *RdP* de la figure 1.15, est fonction des informations fournies par le processus de supervision et par le processus de pronostic de défaillance. La figure 1.15 représente les modèles *RdP* modélisant la disponibilité de l'équipement de maintenance.

Les *RdP* présentent l'avantage d'être un outil mathématique et graphique permettant de modéliser les différents modes de fonctionnement des composants et les évolutions entre ces différents modes. La synchronisation entre les différents *RdP* est réalisée grâce à des messages de synchronisation en fonction des résultats du processus de supervision et du processus de pronostic de défaillance. Le processus de supervision utilisé dans ce manuscrit est basé sur les techniques de *RdF*.

Le processus de supervision mettant en œuvre les techniques de *RdF* s'appuie généralement sur des modèles de référence du système fondé sur l'expérience. Cependant, le système réel est souvent soumis à une évolution au cours du temps de ses caractéristiques intrinsèques qui provoqueront une évolution des modèles de référence. Nous parlons alors du *système dynamique évolutif (SDE)*. Certains auteurs emploient le terme de système non-stationnaire [65, 58]. Cette non stationnarité du procédé peut être source d'alarmes intempestives. Elle impose, de plus des mises à jour plus fréquentes et/ou des actions de maintenance régulières qui permettent de redéfinir les modèles de références sur lesquelles se fondent le processus de supervision des systèmes dynamiques. Un modèle de référence (modèle de procédé) définit le comportement normal ou anormal du procédé [29].

Il n'y a que peu de travaux qui envisagent l'actualisation des modèles de références du processus de supervision pour la mise en œuvre d'une stratégie de maintenance adaptée pour des systèmes évolutifs. La problématique liée à la maintenance des systèmes dynamiques évolutifs est présentée dans la section suivante.

1.6 Problématique liée aux Systèmes Dynamiques Évolutifs (SDE)

1.6.1 Caractéristiques des SDE

Un système évolutif est soumis à des évolutions qui induisent des changements de dynamique. Ces changements peuvent être dus soit à une variation normale des paramètres du système, soit à des dégradations, soit à des défauts affectant ses caractéristiques intrinsèques et son comportement. L'évolution des caractéristiques propres au système, peut induire une modification de la structure du modèle représentant sa dynamique, ou tout au moins, des paramètres de ce modèle [64]. Les variations des caractéristiques intrinsèques des systèmes évolutifs sont généralement non contrôlées au cours du temps. Beaucoup de processus peuvent être caractérisés par des dynamiques évolutives au cours de leur fonctionnement. Dans plusieurs domaines, il est aisé de trouver des exemples de systèmes dynamiques évolutifs. Une boîte de vitesse de voiture peut être

considérée comme un système évolutif, dans la mesure où, d'une part, la dynamique du véhicule change en fonction de la vitesse enclenchée, et d'autre part, cette dynamique est directement impactée par la performance du moteur de la voiture par exemple. En effet, la puissance du moteur peut être amenée à diminuer au cours du temps. Dans le domaine de l'environnement, nous pouvons considérer l'exemple d'un canal de transport d'eau qui peut être utilisé en différents points de fonctionnement selon l'usage et la période de l'année, et qui est soumis à des phénomènes d'envasement. Au cours du temps, la dynamique du canal peut être modifiée par ces phénomènes. Finalement, un dernier exemple est le cas d'un processus biologique de traitement anaérobie de boue et en particulier les digesteurs. Les matières organiques fermentent grâce à des ensembles de bactéries en trois étapes, qui sont l'hydrolyse, l'acidogenèse et la méthanogenèse. En fonction de la phase de production, les dynamiques liées à la fermentation diffèrent. Une évolution du PH dans le digesteur peut entraîner une modification de ces dynamiques et de la performance du processus de traitement de boue.

En reprenant le cas d'un modèle LTI sous la forme de l'équation d'état, en supposant que la structure du modèle reste inchangée, la prise en compte de l'aspect évolutif conduirait à l'expression suivante :

$$\begin{cases} \dot{x}(k) = A(\eta)x(k) + B(\eta)u(k), \\ y(k) = C(\eta)x(k) + D(\eta)u(k), \end{cases} \quad (1.14)$$

avec η une variable de séquencement. Les matrices A , B , C et D sont alors dépendantes de η et imposent une remise à jour des paramètres du modèle du système.

Dans le cas de la multi-modélisation, le multi-modèle de la relation (1.2) devient :

$$\begin{cases} \dot{x}(k) = \sum_{i=1}^M \mu_i(\zeta(k), \eta) \{A_i(\eta)x(k) + B_i(\eta)u(k)\}, \\ y(k) = \sum_{i=1}^M \mu_i(\zeta(k), \eta) \{C_i(\eta)x(k) + D_i(\eta)u(k)\}, \quad i \in \{1, \dots, M\}, \end{cases} \quad (1.15)$$

où les matrices A_i , B_i , C_i sont dépendantes des modes de fonctionnement et de la variable η caractérisant l'évolution du système.

Afin d'illustrer la définition et la modélisation des SDE , nous proposons de considérer un cas simple qui peut présenter des dynamiques linéaires, non linéaires, ou avec commutations selon les hypothèses de fonctionnement et/ou de dégradation. Il s'agit d'un réservoir composé d'une partie conique et d'une partie cylindrique (*voir* figure 1.16). Il est équipé de deux vannes TOR (Tout Ou Rien) qui permettent de l'alimenter et de le vidanger.

Exemple 2

Les modèles LPV (1.14) ou multi-modèle (1.15) peuvent être utilisées pour modéliser l'état de fonctionnement du réservoir. Dans cet exemple, le paramètre η est supposé mesurable et l'évolution de la dynamique du réservoir est uniquement due à l'encrassement. Nous considérons le fonctionnement du réservoir sur la partie cylindrique autour d'un point de fonctionnement, avec les dimensions du réservoir suivantes, avant et après encrassement :




FIGURE 1.16 – Système de réservoir soumis aux encrassements de ses parois.

- $h_2 = 0,75 \text{ m}$, $h_2^E = 0,75 \text{ m}$,
- $S = 2 \text{ m}^2$, $S^E = 1,9 \text{ m}^2$,
- $s_1 = 0,2 \text{ m}^2$, $s_1^E = 0,17 \text{ m}^2$,

avec h_2 la hauteur d'eau dans la partie cylindrique, h_2^E la hauteur d'eau dans le cylindrique après l'encrassement, S la section du cylindre, S^E la section du cylindre après l'encrassement, s_1 la section de la vanne de vidange et s_1^E la section de vanne de vidange après l'encrassement.

La figure 1.17 illustre la réponse du système réservoir, avant et après l'encrassement de la cuve. La courbe en trait continu est le débit de sortie du système, la courbe du débit de sortie donné par le multi-modèle est confondue à la courbe du débit du système, la courbe en trait discontinu est le débit de sortie du système après la dégradation ou la modification de la section s_1 (s_1 section de la vanne de vidange). Nous notons qu'une faible évolution des paramètres du réservoir due à l'encrassement conduit à une modification importante de la dynamique du système. La remise à jour du modèle au bout d'un certain temps, permet de prendre en compte ces modifications, mais l'évolution entre ces deux instants n'a pas été prise en compte.




FIGURE 1.17 – Étude de la dynamique de la cuve, la courbe en trait continu est le Q_s du système, la courbe donnée par le multi-modèle est confondue avec le Q_s du système et la courbe en trait discontinu est le Q_s du système après la modification de s_1 et S .

La réécriture des modèles *LPV* et multi-modèle peut être réalisée de manière identique. Cependant, la remise à jour des paramètres des modèles est difficilement réalisable du fait que

les éléments influant sur le système ne sont pas *a priori* connus.

La difficulté liée à l'utilisation de ces modèles réside alors dans l'impossibilité de connaître l'évolution des systèmes dynamiques de façon déterministe et exacte, sur la totalité de la durée de vie du système. L'utilisation de ces modèles nécessiterait donc une remise à jour à une certaine fréquence des paramètres ou des grandeurs qui pourraient modifier la dynamique des systèmes. Les fréquences de remise à jour sont difficilement optimisables, et les ressources nécessaires à cette mise à jour sont lourdes à mettre en place, surtout pour des systèmes complexes.

Une autre possibilité consisterait à utiliser les techniques de *RdF* pour la modélisation des systèmes évolutifs (voir figure 1.11.b).

La modélisation du système de réservoir de la figure 1.16 par les techniques *RdF* est présentée par l'exemple ci-dessous.

Exemple 3 *Pour surveiller en continu le réservoir, nous utilisons les indicateurs sensibles à l'état de fonctionnement du système. Ces indicateurs doivent être des paramètres invariants par rapport aux modes de fonctionnement normaux du procédé à surveiller. Les indicateurs $x_{k,1}$ et $x_{k,2}$ définis selon la relation (1.16), sont utilisés pour surveiller l'état de fonctionnement du réservoir.*

$$\begin{cases} x_{k,1} = \begin{cases} x_{11} = h(k) - h_{co}(k) & \text{si } h(k) \leq h_1, \\ x_{12} = h(k) - h_{cy}(k) & \text{si } h(k) > h_1, \end{cases} \\ x_{k,2} = h(k) - \frac{1}{2g} \left(\frac{Q_s}{\pi r_i^2} \right)^2, \text{ avec } r_i \text{ rayon de la vanne de vidange,} \\ X_k = [x_{k,1} \ x_{k,2}]^\top \text{ vecteur d'observation du réservoir,} \end{cases} \quad (1.16)$$

avec

$$\begin{cases} h_{co}(k) = \left(\frac{3(Q_e - Q_s)}{\pi \tan^2(\theta)} k \right)^{1/3}; \quad k \in \left[0 \quad T_{max} = \frac{\pi \tan^2(\theta) h_1^3}{3(Q_e - Q_s)} \right], \\ h_{cy}(k) = \frac{(Q_e - Q_s)}{\pi R^2} (k - T_{max}). \end{cases} \quad (1.17)$$

et h_{co} est le niveau d'eau dans la partie conique et h_{cy} est le niveau d'eau dans la partie cylindrique.

Les composantes du vecteur X_k sont exprimées soit en fonction de R , soit en fonction de θ ou soit en fonction de r_i . L'indicateur exprimé en fonction de R , de θ et r_i permettent respectivement de surveiller l'encrassement de la partie cylindrique, de la partie conique et de la vanne de vidange. Toute évolution de ces paramètres se traduit par une évolution des indicateurs $x_{k,1}$ ou $x_{k,2}$ formant le vecteur d'observation $X_k = [x_{k,1} \ x_{k,2}]^\top$.

Nous avons procédé par simulation sous *MatLab* pour obtenir les classes modélisant les deux modes de fonctionnement du système réservoir en fonction de la hauteur d'eau. La figure 1.18 illustre les deux classes correspondant aux modes de fonctionnement normaux du réservoir.

Dans cet exemple, les classes correspondent aux modes de fonctionnement. Les défaillances (catalectiques, ou progressives) sur un tel système se manifestent dans l'espace de décision par

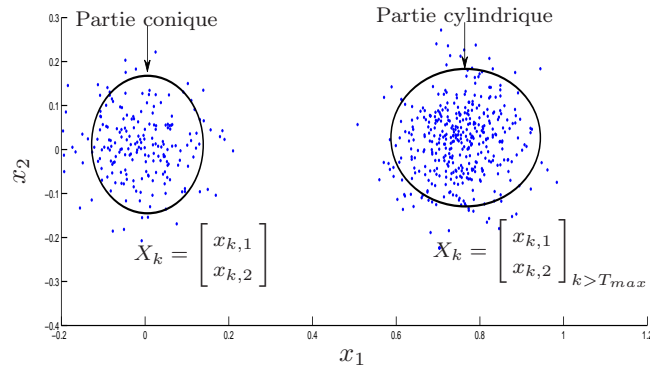


FIGURE 1.18 – Modélisation des modes de fonctionnement du réservoir par RdF .

des changements brusques comme illustré sur la figure 1.19.a, ou des évolutions d'un ou plusieurs modes de fonctionnement. Il existe deux types d'évolution des modes de fonctionnement :

- évolution rapide (ou dérives rapides) qui est caractérisée par un glissement des observations dans l'espace de représentation (voir figure 1.19.b),
- évolution lente (ou dérives lentes) qui est caractérisée par une évolution lente du mode de fonctionnement (voir figure 1.19.c).




FIGURE 1.19 – Différents types de dérives de fonctionnement.

Les modes de fonctionnement représentés sur la figure 1.18, peuvent évoluer au cours du temps entre les deux modes de fonctionnement normaux, ou évoluer vers un mode défaillant correspondant à l'encrassement de la partie conique et/ou de la partie cylindrique du système réservoir. Ces évolutions sont illustrées par l'exemple ci-dessous.

Exemple 4 *L'évolution du système entre les modes de la figure 1.18 est considérée comme une évolution normale. Cependant ces classes peuvent être soumises à des défauts qui entraînent un changement de dynamique, dus par exemple à l'encrassement des parois du réservoir. Pour obtenir l'évolution du mode de fonctionnement de la partie conique, nous procédons à une évolution des paramètres θ et r_i . La figure 1.20.a illustre la dérive rapide du mode de fonctionnement de la partie conique. La figure 1.20.b représente la dérive lente du mode de fonctionnement de la partie conique.*




FIGURE 1.20 – Dérives des modes de fonctionnement : (a) - dérives rapides, (b) - dérives lentes.

Ces deux exemples montrent l'intérêt de disposer d'outils capables d'apprendre (mémoriser et généraliser) les connaissances utiles extraites du processus, de suivre leurs évolutions dans le temps et d'actualiser la base de connaissance en continu, c'est-à-dire détecter de nouveaux modes et les inclure dans la base. Les outils doivent être également capables de prédire l'état futur du procédé ou de ses composants pour l'aide à la décision afin de planifier des actions de maintenance prévisionnelle. Dans le paragraphe suivant, les outils nécessaires pour la maintenance prévisionnelle des *SDE* sont présentés.

1.6.2 Propriétés nécessaires pour la mise en œuvre d'outils de maintenance prévisionnelle des *SDE*

La mise en œuvre de la maintenance prévisionnelle des systèmes évolutifs repose sur quatre modules :

1. Le module de modélisation basé sur les techniques de *RdF*. Ce module doit être capable d'établir une représentation dynamique des différents modes de fonctionnement.
2. Le module de surveillance des systèmes évolutifs. Ce module doit être capable de suivre en continu l'état du système et de détecter tout changement de comportement du système en particulier des dérives lentes de fonctionnement qui sont des dérives difficilement détectables, par des outils de détection classiques.
3. Le module de diagnostic des *SDE*. Ce module doit être capable d'identifier et de caractériser les modes de fonctionnement du système et d'avertir l'utilisateur de l'éventuelle apparition d'un nouveau mode de fonctionnement. Pour ce second point, il consiste en un échange entre le module de diagnostic et un expert du système, visant à labelliser les nouveaux modèles en termes de modes de fonctionnement.
4. Un processus de pronostic exploitant les indicateurs de dégradation issus du module de surveillance afin de prédire l'état futur du système.

L'objectif de la thèse est de proposer des outils de supervision et de pronostic de défaillance pour la mise en œuvre d'une stratégie de maintenance prévisionnelle de systèmes dynamiques évolutifs, c'est-à-dire des outils capable de répondre aux besoins de la maintenance prévisionnelle des *SDE*.

1.7 Conclusion

Dans ce chapitre, nous avons montré l'intérêt de mettre en œuvre une politique de maintenance préventive en particulier de maintenance prévisionnelle des systèmes dynamiques évolutifs. En effet, les applications industrielles sont des processus complexes généralement caractérisés par des comportements évolutifs. Nous avons également montré l'importance de la maintenance prévisionnelle dans la compétitivité des entreprises, ainsi que son rôle dans la réduction des risques.

La mise en œuvre d'une politique de maintenance prévisionnelle des systèmes évolutifs se traduit par le développement d'un système de supervision capable de surveiller en continu l'état de fonctionnement du procédé et d'un processus de pronostic capable de prévoir l'état futur du système en temps réel. Le processus de supervision présenté dans ce chapitre est constitué d'un module de modélisation, d'un module de surveillance (suivi/détection) et d'un module de diagnostic. La modélisation est au cœur de la stratégie de maintenance prévisionnelle des *SDE*. Elle a pour objectif d'établir une représentation dynamique des différents modes de fonctionnement du procédé. Ainsi, ces modes de fonctionnement peuvent être modélisés au fur et à mesure de leur apparition et leur définition actualisée en continu. La méthode de modélisation retenue dans ce mémoire de thèse est basée sur les techniques de Reconnaissance des Formes.

Pour le système de supervision des *SDE*, il est nécessaire de disposer d'outils de suivi, de détection et de diagnostic capables de suivre en ligne l'état de fonctionnement du procédé et de détecter tout changement de comportement de celui-ci. Ainsi, le processus doit être capable de détecter l'apparition de nouveaux modes de fonctionnement et de les inclure dans la base de connaissance. A cet effet, les méthodes de diagnostic adaptatif basées sur les techniques de *RdF* sont présentées dans le chapitre 2.

2

Systeme de supervision adaptatif

2.1 Introduction

Le processus de supervision comme introduit dans le chapitre 1, dans le cas de systemes evolutifs doit s'appuyer sur un outil de modelisation capable d'etablir une representation dynamique des differents modes de fonctionnement, et une technique de detection susceptible de detecter tout changement de comportement du procede. Pour, cela, il est interessant de disposer d'un module de diagnostic par Reconnaissance de Formes (*RdF*) identifiant et caracterisant les modes de fonctionnement du systeme. Le diagnostic par *RdF* a pour role de permettre d'associer les nouvelles observations recueillie sur le systeme a l'un des modes de fonctionnement connus *a priori*. Le diagnostic par *RdF* des systemes dynamiques se heurte souvent au manque de connaissances exhaustives des modes de fonctionnement du systeme. En effet, pour des raisons de cout ou de securite, certains modes defaillants ou dangereux ne peuvent pas etre provoques et seront donc absents de la base de connaissance. Par ailleurs, des modes de fonctionnement existants dans la base de connaissance peuvent evoluer au cours de la vie du procede. Compte tenu des specifications attendues pour le processus de supervision, un systeme de diagnostic base sur la technique de *RdF* floues semble particulierement adapte. La *RdF* floue est basee sur l'apprentissage et permet lorsque des mecanismes d'adaptation sont integres, la detection de nouveautes tout au long de la vie du procede. C'est d'ailleurs dans le domaine des techniques de *RdF* floue que de premieres methodes prometteuses ont ete proposees pour le diagnostic de systemes evolutifs. Parmi ces methodes nous trouvons la methode Fuzzy Pattern Matching (*FPM*). La methode *FPM* proposee par [68] pour des systemes evolutifs, ne necessite pas de connaissance *a priori* sur les modes des modes de fonctionnement. La procedure de la methode *FPM* pour la creation

de nouvelles classes est basée sur une série chronologique composée des dernières observations rejetées du procédé à surveiller. C. Lurette [58] a proposé un algorithme de classification dynamique de données évolutives, *AUDyC* (AUto-adaptive and Dynamical Clustering), permettant de faire une modélisation dynamique des modes de fonctionnement. L'algorithme *AUDyC* est basé sur un réseau de neurones à architecture évolutive permettant de modéliser chaque mode de fonctionnement par une classe caractérisée par un ou plusieurs prototypes gaussiens. Les caractéristiques des prototypes sont adaptées en continu au fur et à mesure que les données recueillies sur le procédé arrivent. Cette méthode ne nécessite pas une connaissance *a priori* sur les modes de fonctionnement du procédé. Une autre méthode de diagnostic adaptatif est proposée par O. Ondel [80]. Cette méthode est basée sur la règle des *k*-plus proches voisins et le maillage de l'espace de représentation. Le maillage de l'espace de représentation est effectué seulement dans les régions où les classes de la base d'apprentissage sont localisées. Une zone de restriction est ainsi définie autour de ces classes. En utilisant ces zones de restriction, les nouvelles classes peuvent être créées ou éliminées de la base de connaissance.

De plus, une méthode de diagnostic adaptatif *LAMDA* (Learning Algorithm for Multivariate Data Analysis) basée sur l'évaluation de l'adéquation des observations à chaque classe de la base de connaissance a été développée par [7] suite à l'idée originale proposée dans [5]. La méthode *LAMDA* utilise une classe non informative, notée *NIC* (Non Informative Class) pour détecter et créer de nouvelles classes. Cette approche ne nécessite pas non plus une connaissance *a priori* des modes de fonctionnement du procédé pour réaliser la classification.

Dans la section 2.2 de ce chapitre, nous présentons le principe du diagnostic par *RdF* floue qui est construit à partir des fonctions d'appartenance. Les méthodes de diagnostic adaptatif sont présentées dans la section 2.3. Enfin la méthode que nous retenons pour la mise en œuvre de la politique de maintenance de systèmes évolutifs est présentée dans la section 2.4.

2.2 Principe du diagnostic par *RdF* floue

2.2.1 Technique de *RdF* floue

En *RdF* classique, l'appartenance d'un vecteur d'observation $X_k = [x_{k,1} \ \cdots \ x_{k,D}]^T$ à une classe C_i est définie à l'aide d'une fonction binaire appelée fonction caractéristique, notée $\mu(X_k, C_i)$ (voir figure 2.1).

$$\mu(X_k, C_i) = \begin{cases} 1 & \text{si } X_k \in C_i, \\ 0 & \text{si } X_k \notin C_i. \end{cases} \quad (2.1)$$

Il est difficile d'associer une vérité binaire aux modes de fonctionnement, lorsqu'au moins un des modes évolue lentement au cours du temps. Il peut s'agir par exemple de l'usure d'un composant du système. Initialement, le composant est dans un mode de fonctionnement normal puis, il se dégrade jusqu'à atteindre un état d'usure inacceptable (état défaillant) : il y a bien une transition d'un état normal vers un état anormal et il est difficile de caractériser cette transition à l'aide d'une table de vérité binaire.




FIGURE 2.1 – Concept d'appartenance au sens classique et au sens flou.

L'imprécision des informations issues d'un système réel peut également limiter les performances de l'approche classique de *RdF*. Une observation située au centre d'une classe ou en bordure de cette même classe est affectée de la même manière par l'approche de *RdF* classique. Pourtant ces deux observations n'ont pas la même représentativité [80]. La théorie des ensembles flous proposée par Zadeh [106] est considérée comme l'une des solutions alternatives possibles pour gérer les types d'incertitude intervenant dans la conception d'un système de diagnostic. La *RdF* intégrant les principes de cette théorie a donné naissance à la *RdF* floue. La théorie des ensembles flous substitue la notion de fonction caractéristique dans la *RdF* classique à la notion de fonction d'appartenance (voir figure 2.1).

La fonction d'appartenance permet de qualifier le degré de compatibilité entre une observation X_k et une classe C_i . Elle est définie par :

$$\mu(X_k, C_i) \in [0, 1] \text{ avec } \begin{cases} \mu(X_k, C_i) = 0 & \text{si } X_k \notin C_i, \\ 0 < \mu(X_k, C_i) < 1 & \text{si } X_k \text{ appartient graduellement à } C_i, \\ \mu(X_k, C_i) = 1 & \text{si } X_k \in C_i. \end{cases} \quad (2.2)$$

La technique de *RdF* floue permet d'obtenir une fonction d'appartenance graduelle utilisée par les méthodes de diagnostic. Cette fonction d'appartenance est une fonction continue à valeurs généralement comprises dans l'intervalle $[0,1]$. Le vecteur d'observation X_k est d'autant plus compatible avec C_i que son degré d'appartenance est proche de 1. Cet aspect graduel de la fonction d'appartenance qui n'est plus discontinue, permet de nuancer le degré de ressemblance d'une observation à une classe. La continuité de la fonction d'appartenance offre la possibilité de suivre l'évolution des nouvelles observations dans l'espace de décision flou, c'est-à-dire de localiser à chaque instant le vecteur d'observation par rapport à l'ensemble des classes de la base de connaissance [68].

Un système de diagnostic par *RdF* floue est construit à partir des fonctions d'appartenance aux classes. Pour une application au diagnostic, les adaptations faites au principe de *RdF* floue se situent dans la phase d'analyse et la phase d'exploitation [18].

2.2.2 Phase d'analyse

2.2.2.1 Détermination de l'espace de décision flou

L'étape de classification floue permet de définir les paramètres des fonctions d'appartenance associés aux modèles décrivant les différents modes de fonctionnement. Tout comme en *RdF* classique, plusieurs stratégies sont envisageables en fonction de la connaissance disponible sur les observations d'apprentissage [58].

- *En mode supervisé*, les observations d'apprentissage sont déjà étiquetées en modes de fonctionnement. Il s'agit alors de réaliser un apprentissage supervisé pour définir des modèles représentant les modes de fonctionnement en établissant pour chacun d'entre eux une fonction d'appartenance.
- *En mode non supervisé*, des algorithmes de classification non supervisée sont utilisés. De nombreux algorithmes existent selon la structure de classification recherchée (partition, hiérarchie, ...). Parmi les plus connus, nous pouvons citer celui des C-moyennes floues (Fuzzy C-Means) qui permet de construire une partition floue des données d'apprentissage.

Exemple 5 La méthode du Fuzzy C-Means (FCM) est définie comme suit [12] :

- considérons l'ensemble de N points suivant :

$$\mathbb{X} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,N} \\ \vdots & \vdots & \vdots \\ x_{D,1} & \cdots & x_{D,N} \end{bmatrix}, \quad (2.3)$$

où D est la dimension de l'espace de représentation.

- supposons que les N points peuvent être regroupés en N_c classes, avec $N_c < N$; les classes sont décrites par leur centre, avec M_i $1 \leq i \leq N_c$.

- considérons la matrice de proximité suivante :

$$U = \begin{bmatrix} \mu_{1,1} & \cdots & \mu_{1,N} \\ \vdots & \vdots & \vdots \\ \mu_{N_c,1} & \cdots & \mu_{N_c,N} \end{bmatrix}, \quad (2.4)$$

avec $\mu_{i,l}$ le degré d'appartenance de l'observation X_l à la classe C_i de centre M_i . L'expression de $\mu_{i,l}$ est donnée par :

$$\mu_{i,l} = \left[\sum_{i'=1}^{N_c} \left(\frac{\|X_l - M_i\|}{\|X_l - M_{i'}\|} \right)^{\frac{2}{m-1}} \right]^{-1}, \quad (2.5)$$

et

$$M_i = \frac{\sum_{l=1}^N (\mu_{i,l})^m X_l}{\sum_{l=1}^N (\mu_{i,l})^m}, \quad 1 \leq i \leq N_c, \quad (2.6)$$

où m est un coefficient flou, généralement fixé à 2.

- calculer la matrice U de façon itérative jusqu'à :

$$\|U^k - U^{k-1}\| < \epsilon, \quad (2.7)$$

avec ϵ le seuil de convergence qui est choisi par l'utilisateur et k instant courant.

Dans cet exemple, des données de simulation sont utilisées. Ces données seront structurées en classes en utilisant une méthode de classification. Les classes déterminées par la méthode des C-moyennes floues et les trajectoires décrites par le centre de chaque classe avant leur stabilisation sont représentées sur la figure 2.2.

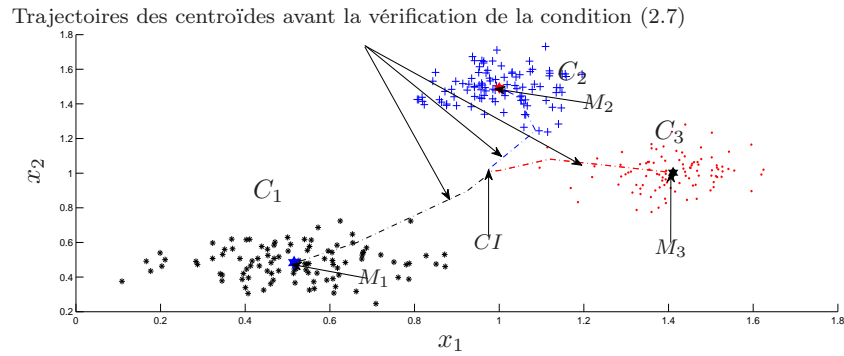


FIGURE 2.2 – Centroïdes de trois classes déterminées par la méthode C-moyennes floues.

Les centroïdes M_j des classes C_i sont adaptés itérativement depuis les Conditions Initiales (CI) jusqu'aux conditions finales représentées sur la figure 2.2. Les centroïdes obtenus par l'algorithme FCM sont aussi appelés des prototypes [77]. Le degré d'appartenance d'une nouvelle observation X_k aux N_c classes est calculé en fonction de la distance entre X_k et les différents prototypes.

2.2.2.2 Représentativité des modes de fonctionnement

Les algorithmes de classification floue non supervisée (FCM, PCM, ...) permettent d'identifier parmi les données recueillies sur le système des "formes types" nommées "prototypes" P_j . Dans ce manuscrit, les prototypes sont des points représentatifs des formes types dans l'espace de représentation. Nous définissons $\mu(X_k, P_j)$ le degré d'appartenance de l'observation X_k au prototype P_j et $\mu(X_k, C_i)$ le degré d'appartenance de X_k à la classe C_i correspondant au modèle i du mode de fonctionnement. La fonction d'appartenance $\mu(X_k, P_j)$ est généralement établie en fonction de la distance entre l'observation X_k et le prototype P_j de la classe C_i [58, 61], c'est-à-dire :

$$\mu(X_k, P_j) = f(d(X_k, P_j)).$$

Le degré d'appartenance $\mu(X_k, P_j)$ doit satisfaire les deux conditions suivantes : être proche de 1 si l'observation X_k appartient au prototype P_j et tendre vers 0 si l'observation X_k s'éloigne

de P_j . Les modèles de prototypes les plus utilisés sont des modèles gaussiens [58]. Leur fonction d'appartenance est donnée par :

$$\mu(X_k, P_j) = \exp(-\lambda_j \cdot d(X_k, P_j)^2), \quad (2.8)$$

où λ_j est une constante utilisée pour ajuster la "raideur" de la courbe exponentielle.

La distance la plus simple à utiliser dans la relation (2.8) est la distance Euclidienne définie par la relation suivante :

$$d(X_k, P_j)^2 = (X_k - M_{P_j}) (X_k - M_{P_j})^\top, \quad (2.9)$$

avec M_{P_j} est le centre du prototype gaussien P_j .

Cependant, cette distance ne prend pas en compte la dispersion des données selon les composantes du vecteur d'observation. Dans ce contexte, la distance de Mahalanobis est privilégiée, car elle prend en compte la dispersion des données appartenant à une même classe. La distance de Mahalanobis est donnée par :

$$d(X_k, P_j)^2 = (X_k - M_{P_j}) \Sigma_{P_j}^{-1} (X_k - M_{P_j})^\top, \quad (2.10)$$

avec $\Sigma_{P_j}^{-1}$ l'inverse de la matrice de covariance du prototype P_j .

Dans [58], deux approches d'association des P_j aux C_i modélisant les modes de fonctionnement du système ont été proposées.

- l'approche mono-prototype : cette approche suppose qu'une classe représentant les modes de fonctionnement du système ne peut être modélisée que par un seul et unique prototype. Ainsi, lorsqu'un mode de fonctionnement est modélisé par un seul prototype, nous avons $\mu(X_k, C_i) = \mu(X_k, P_j)$, avec $P_j \in C_i$.
- l'approche multi-prototype : si la forme de la classe est complexe, il devient nécessaire de définir plusieurs prototypes pour mieux modéliser le mode de fonctionnement du système. La fonction d'appartenance $\mu(X_k, C_i)$ d'une observation X_k à la classe C_i peut être alors définie à partir des fonctions d'appartenance $\mu(X_k, P_j)$ aux différents N_{p_i} prototypes de la classe C_i par :

$$\mu(X_k, C_i) = \mu(X_k, P_1) \cup \dots \cup \mu(X_k, P_{N_{p_i}}), \quad (2.11)$$

où l'opérateur \cup est dans ce cas une t-conorme, qui peut prendre différentes formes [18], telles que l'opérateur :

- somme bornée :

$$\mu(X_k, C_i) = \min \left[1, \sum_{l=1}^{N_{p_i}} \mu(X_k, P_l) \right]. \quad (2.12)$$

- max :

$$\mu(X_k, C_i) = \max_{l=1, \dots, N_{p_i}} (\mu(X_k, P_l)). \quad (2.13)$$

2.2.3 Phase d'exploitation

La phase d'exploitation permet d'associer une nouvelle observation à l'une des N_c classes de l'espace de décision. En *RdF* floue, l'espace de décision flou est défini par un ensemble de classes avec leur fonction d'appartenance graduelle.

L'une des règles les plus connues pour associer une nouvelle observation à l'une des classes est le **maximum d'appartenance** défini par :

$$X_k \in C_i \text{ avec } i = \arg \max_{L=1, \dots, N_c} (\mu(X_k, C_L)). \quad (2.14)$$

où X_k est la nouvelle observation à classer. Cette règle consiste à affecter le vecteur d'observation X_k à la classe dont l'appartenance est maximale.

Comme dans le cas classique, l'option de rejet peut être intégrée au module de classification floue pour le rendre adaptatif [18]. Dans la technique de *RdF* floue, le rejet en distance est remplacé par le rejet d'appartenance. Parmi les règles les plus connues, nous citons **la règle du rapport d'appartenance**. Elle s'exprime à l'aide d'un seuil d'appartenance minimal, noté ψ_{\min} pour le rejet d'appartenance et à l'aide d'un seuil de réglage du rejet en ambiguïté, noté ψ_{amb} . Ainsi,

$$X_k \text{ est affectée à la classe } \begin{cases} C_{dist} & \text{si } Card(\xi) = 0, \\ C_{amb} & \text{si } Card(\xi) > 1 \text{ et } \delta(X_k) > \psi_{amb}, \\ C_i & \text{sinon,} \end{cases} \quad (2.15)$$

où ξ désigne l'ensemble des classes vérifiant l'expression suivante :

$$\xi = \{C_j / \mu(X_k, C_j) \geq \psi_{\min}, \text{ pour } j = 1, \dots, N_c\}. \quad (2.16)$$

et $\delta(X_k)$ désigne le rapport d'appartenance utilisé pour l'option de rejet d'ambiguïté :

$$\delta(X_k) = \frac{\mu_p(X_k)}{\mu(X_k, C_i)} \text{ avec } \begin{cases} \mu(X_k, C_i) = \max_{i'=1, \dots, N_c} (\mu(X_k, C_{i'})), \\ \mu_p(X_k) = \max_{L=1, \dots, N_c, L \neq i} (\mu(X_k, C_L)). \end{cases} \quad (2.17)$$

Il y a une ambiguïté de décision entre au moins deux classes, si et seulement si $\delta(X_k)$ est proche de 1, c'est-à-dire $\mu(X_k, C_i) \approx \mu_p(X_k)$. X_k est associée à C_i lorsque $\delta(X_k)$ tend vers 0 ($\mu(X_k, C_i) \gg \mu_p(X_k)$). La classification se fait alors selon la règle d'appartenance maximale.

Comme dans le cas du diagnostic par *RdF* classique, le système de diagnostic par *RdF* floue se heurte souvent au problème de l'insuffisance de la connaissance *a priori* sur les modes de fonctionnement du système réel. Ainsi, au cours de la vie du système, les modes de fonctionnement de celui-ci peuvent évoluer et/ou de nouveaux modes peuvent apparaître. Un mode de fonctionnement du système peut évoluer lentement ou rapidement vers un autre mode connu ou inconnu. Pour ces raisons, la mise en œuvre d'un système de diagnostic adaptatif peut être intéressante, en permettant au processus de supervision d'être capable de détecter des nouveautés et de les inclure dans la base de connaissance. Les méthodes de diagnostic adaptatif feront l'objet de la section suivante.

2.3 Méthodes de diagnostic adaptatif

Le cas où la connaissance sur les modes de fonctionnement du procédé industriel est exhaustive n'est pas usuel en diagnostic. De ce fait, de nouveaux modes peuvent apparaître au cours du temps, et, dans ce cas, l'affectation systématique d'une nouvelle observation X_k à une classe connue peut conduire à une erreur de diagnostic [80]. Afin de pallier cette erreur, le système de diagnostic comporte deux options de rejet : le rejet d'ambiguïté et le rejet de distance [97]. Le rejet en ambiguïté permet d'éviter de prendre une décision lorsqu'un doute sur l'appartenance de l'observation existe, notamment dans le cas où plusieurs classes sont en compétition. Le nombre d'observations rejetées en ambiguïté peut être utilisé pour mesurer l'efficacité de l'outil de classification. Tandis que l'intérêt du rejet de distance, est qu'il permet la mise en évidence de nouveaux modes de fonctionnement du système [35]. Le processus de supervision de systèmes évolutifs doit donc être capable de détecter l'apparition des nouveaux modes de fonctionnement, puis de les intégrer dans la base de connaissance.

La figure 2.3 représente une architecture d'un système de diagnostic adaptatif. A chaque présentation d'une nouvelle observation X_k , le module de décision affecte l'observation présentée, à l'une des N_c classes connues *a priori* ou à la classe de rejet de distance C_{dist} si l'observation est éloignée de toutes les N_c classes, ou à la classe de rejet d'ambiguïté C_{amb} si elle appartient au moins à deux classes de la base de connaissance. Lorsque la nouvelle observation X_k est affectée à la classe C_i avec $i \in \{1, \dots, N_c\}$, les caractéristiques (paramètres du modèle) de celle-ci sont mises à jour. La mise à jour en continue des paramètres des modèles permet de suivre en temps réel l'évolution des classes correspondant aux modes de fonctionnement. Les observations affectées à la classe C_{dist} seront utilisées pour mettre en évidence l'apparition de nouveaux modes de fonctionnement du système. Le diagnostic adaptatif permet de déterminer à chaque instant l'état dans lequel le système se trouve et éventuellement de décider s'il est nécessaire de créer une nouvelle classe correspondant à un nouveau mode de fonctionnement. Lorsque des nouveaux sont détectés, l'expert ou l'utilisateur les labellise en termes de modes de fonctionnement les nouvelles classes identifiées. La confirmation et la labellisation se feront en fonction du nombre minimal d'observations affectées à la classe C_{dist} par le module de décision et en fonction de la similarité des observations contenues dans C_{dist} .

Les méthodes adaptées au diagnostic des systèmes évolutifs sont présentées par la suite.

2.3.1 Méthode Fuzzy Pattern Matching (*FPM*)

Fuzzy Pattern Matching (*FPM*) est une méthode de classification de données qui utilise la théorie des possibilités, afin de déterminer les fonctions d'appartenance. Cette théorie est une extension de la théorie des ensembles flous introduite par Zadeh en 1965 [106]. La théorie des possibilités est détaillée plus amplement dans [68]. Le principe de fonctionnement de la méthode *FPM* repose sur deux phases : la phase d'apprentissage et la phase de classification.

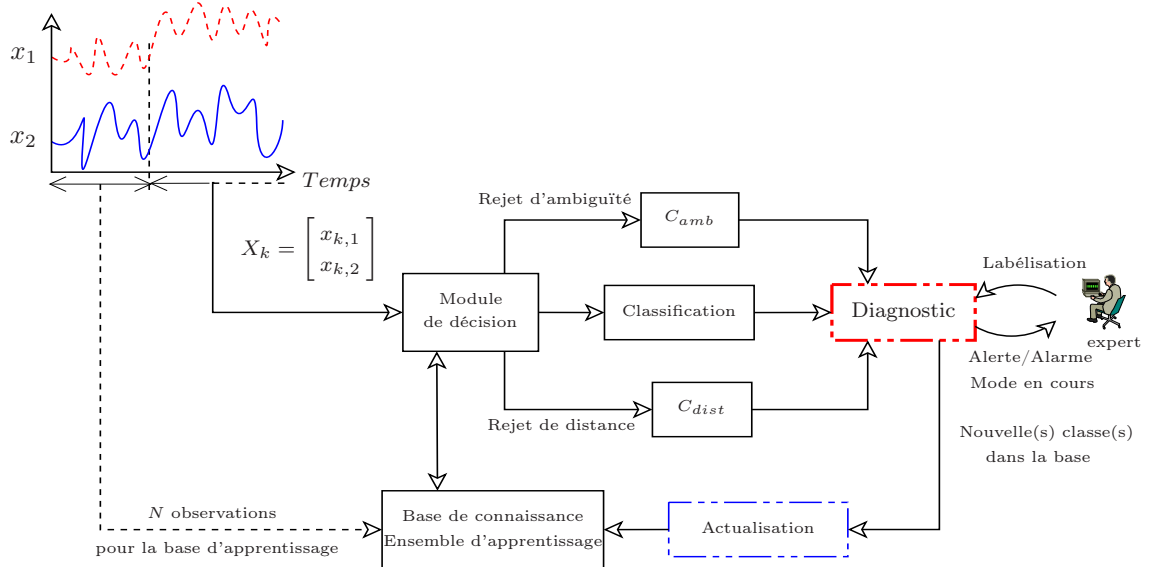


FIGURE 2.3 – Architecture d'un système de diagnostic adaptatif.

2.3.1.1 Phase d'apprentissage

La phase d'apprentissage supervisée permet la création des fonctions d'appartenance utilisées pour associer chaque nouvelle observation $X_k = [x_{k,1} \cdots x_{k,D}]^T$, à l'une des différentes classes connues de la base de connaissance. Chaque fonction d'appartenance est représentée par une densité de probabilité suivant chaque composante de l'observation X_k associée à la classe C_i . Les distributions de possibilité sont calculées à partir des distributions de probabilité, qui sont elles mêmes estimées à partir d'histogrammes de données. Les histogrammes de chacune des classes représentés sur la figure 2.4 sont construits à partir de N_i données d'apprentissage. Ainsi, les bornes inférieures et supérieures de l'histogramme de chaque classe C_i suivant chaque composante, sont des valeurs minimales et maximales des observations contenues dans la classe C_i suivant la composante v .




FIGURE 2.4 – Nuages de points repartis en deux classes (mode supervisé).

La probabilité associée à chaque barre de l'histogramme est donnée par la relation suivante

[44].

$$p_{v,i}(b_\alpha)_{\alpha=1,\dots,h_{v,i}} = \frac{n_\alpha}{N_i}; \quad v = 1, \dots, D \text{ et } i = 1, \dots, N_c, \quad (2.18)$$

où $p_{v,i}(b_\alpha)$ la probabilité associée au centre de la barre b_α , n_α le nombre de points contenus dans la barre b_α et N_i est le nombre total de données relatives à la classe C_i .

L'histogramme et la densité de probabilité $p_{v,i}$ de la classe C_1 de la figure 2.4 suivant chaque composante v sont représentés sur la figure 2.5.




FIGURE 2.5 – Histogramme et densité de probabilité $p_{v,1}$ de la classe C_1 .

La possibilité d'appartenance de X_k à la classe C_i est donnée par :

$$\pi_{v,i}(b_\alpha) = \sum_{n=1}^{h_{v,i}} \min(p_{v,i}(b_\alpha), p_{v,i}(b_n)). \quad (2.19)$$

$h_{v,i}$ représente le nombre de barres de l'histogramme suivant la composante v de la classe i . Le nombre de barres $h_{v,i}$ est un paramètre de la méthode *FPM*. Il a une forte influence sur la performance de la méthode. Son choix est indépendant du nombre de classes. Plusieurs techniques d'estimation de $h_{v,i}$ sont proposées dans [68].


La largeur $\Delta_{v,i}$ de chacune des barres de la composante v est donnée par :

$$\begin{cases} \Delta_{v,i} = \frac{\max(\mathbf{T}_{v,i}) - \min(\mathbf{T}_{v,i})}{h_{v,i}}, \\ \mathbf{T}_{v,i} = [x_{1,v} \cdots x_{N_i,v}]_{1 \leq v \leq D}. \end{cases} \quad (2.20)$$

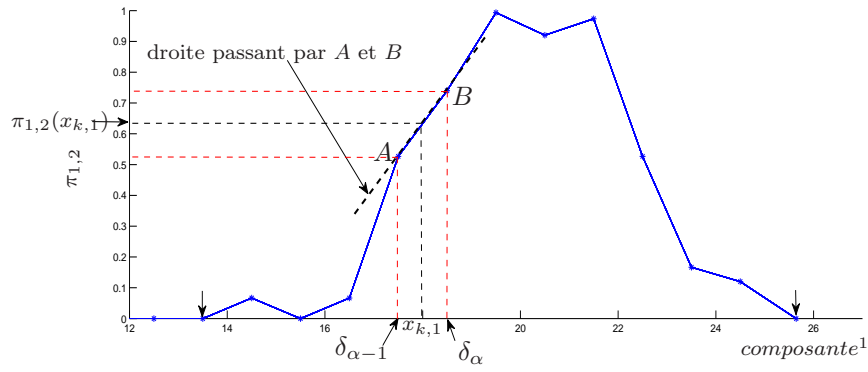
Rappelons que les histogrammes de possibilité sont estimés à partir des histogrammes de probabilité [68, 44]. L'estimation de la possibilité $\pi_{v,i}(b_\alpha)$ à partir de la probabilité est donnée par la relation (2.19). L'histogramme et la densité de possibilité de la classe C_1 suivant chaque composante sont représentés sur la figure 2.6.

2.3.1.2 Phase de classification

L'affectation d'une nouvelle observation $X_k = [x_{k,1} \cdots x_{k,D}]^\top$ à l'une des classes de la base de connaissance, s'effectue en deux temps : la détermination de la similitude entre la nouvelle


 FIGURE 2.6 – Histogramme et densité de possibilité $\pi_{v,1}$ de la classe C_1 .

observation X_k et les différentes classes, et la décision concernant la classe d'appartenance de la nouvelle observation. La similarité $\pi_{v,i}(x_{k,v})$ entre $x_{k,v}$ et la classe C_i est obtenue en utilisant la projection de la composante $x_{k,v}$ sur la distribution de possibilité $\pi_{v,i}$, comme illustré sur la figure 2.7.


 FIGURE 2.7 – Estimation de $\pi_{1,i}$ d'une composante $x_{k,1}$ de X_k . δ_α est le centre de la barre b_α .

La possibilité d'appartenance $\pi_i(X_k)$ de la nouvelle observation X_k à la classe C_i est finalement donnée par :

$$\pi_i(X_k) = \min(\pi_{1,i}(x_{k,1}), \dots, \pi_{D,i}(x_{k,D})). \quad (2.21)$$

Si toutes les possibilités d'appartenance ($\pi_1(X_k), \dots, \pi_{N_c}(X_k)$) de chaque classe sont déterminées, un opérateur max est utilisé pour décider à quelle classe appartient la nouvelle observation X_k . Le degré d'appartenance de X_k à l'une des N_c classes est donné par la relation suivante.

$$\mu(X_k, C_i) = \pi_i(X_k) \text{ tel que } i = \arg \max(\pi_1(X_k), \dots, \pi_{N_c}(X_k)). \quad (2.22)$$

L'observation X_k est affectée à la classe qui a la plus forte possibilité d'appartenance. Lorsque $\pi_i(X_k) = 0$, l'observation X_k est rejetée par rapport à la classe C_i .

Pour adapter la méthode *FPM* classique à la classification de données évolutives, [69] a proposé une approche intégrant l'apprentissage incrémental dans la méthode *FPM*. Après chaque classement d'une nouvelle observation X_k dans la classe C_i , les densités de probabilité associées aux barres de cette classe suivant chaque composante sont mises à jour. Lorsque la nouvelle observation X_k est affectée à la barre b_l , la mise à jour des probabilités associées aux barres $(b_\alpha)_{\alpha=1, \dots, l, \dots, h_{v,i}}$ est donnée par la relation suivante :

$$\begin{aligned} p'_{v,i}(b_\alpha) &= \left(\frac{n_\alpha}{N_i+1} \right), \quad \alpha=1, \dots, l-1 \\ p'_{v,i}(b_l) &= \frac{n_l+1}{N_i+1}, \\ p'_{v,i}(b_\alpha) &= \left(\frac{n_\alpha}{N_i+1} \right), \quad \alpha = l+1, \dots, h_{v,i}, \end{aligned} \quad (2.23)$$

où N_i est le nombre d'observations dans la classe C_i et n_α le nombre d'observations contenues dans la barre b_α avant le classement de la nouvelle observation dans la classe C_i .

Sur la figure 2.8, les points représentés par des petits cercles sont les nouveaux points classés dans la classe C_1 . Le classement d'un nouveau point dans la classe C_1 déclenche le processus de mise à jour des densités de probabilité associées à chaque composante de celle-ci.

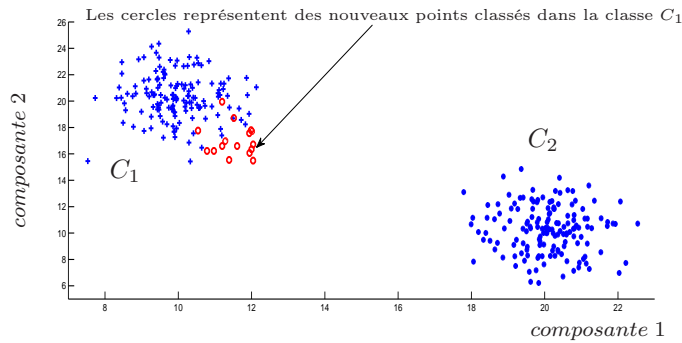


FIGURE 2.8 – Classement de nouvelles observations dans la classe C_1 .

La figure 2.9 représente la densité de probabilité de la composante 1 de la classe C_1 avant et après le classement des nouvelles observations.

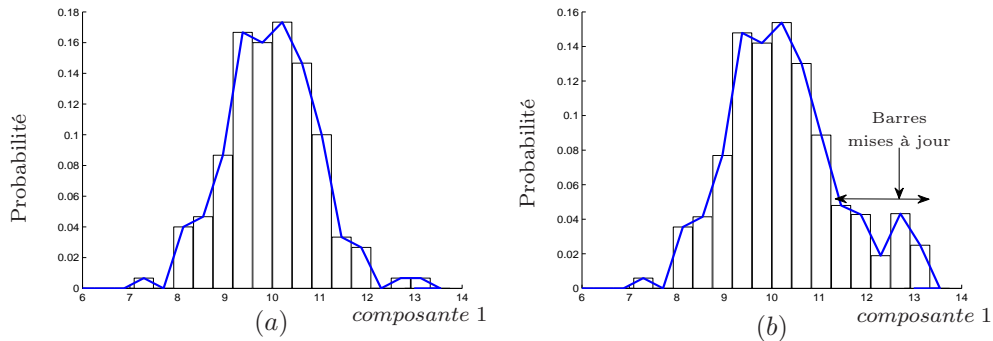


FIGURE 2.9 – Histogramme et densité de probabilité d'appartenance, (a) - avant le classement et (b) - après le classement des nouvelles observations.

2.3.1.3 Procédure de détection d'une nouvelle classe par la méthode *FPM*

La détection d'une nouvelle classe par la méthode *FPM* est basée sur la série chronologique composée des dernières observations rejetées du processus à surveiller [68]. Cette série chronologique sera exploitée afin d'en extraire les informations sur le comportement du processus en termes de rapprochement ou d'éloignement des classes modélisant ces modes de fonctionnement. Quand une classe évolue rapidement ou lentement vers une autre, la possibilité d'appartenance π_i à la classe de départ va diminuer au fur et à mesure que les observations s'éloignent de celle-ci. Tandis que la possibilité d'appartenance à la classe d'arrivée va augmenter au fur et à mesure que les observations se rapprochent de cette classe. Les observations évoluant entre les deux classes sont des observations rejetées. Afin de quantifier la représentativité d'une observation rejetée $X_k^{rej} = [x_{k,1}^{rej} \cdots x_{k,D}^{rej}]^\top$ par chaque composante et pour chaque classe, deux informations sont extraites [68].

- la valeur d'appartenance de son plus proche voisin $x_{k,v}^p$ ⁵.
- la distance entre $x_{k,v}^{rej}$ et $x_{k,v}^p$.

Ces deux informations permettent de définir la fonction d'évolution f^e donnant l'influence de chaque classe i sur l'observation rejetée par rapport à la composante v . La fonction d'évolution est donnée par la relation suivante :

$$f_{v,i}^e = \left(1 - \frac{d(x_{k,v}^p, x_{k,v}^{rej})}{x_{\max,v} - x_{\min,v}} \right)^{\frac{N_c}{\pi_{v,i}(x_{k,v}^p)}}, \quad \text{avec } v = 1, \dots, D; i = 1, \dots, N_c, \quad (2.24)$$

où $x_{\max,v} = \max_{k=1, \dots, N_i} (x_{k,v})$, $x_{\min,v} = \min_{k=1, \dots, N_i} (x_{k,v})$ sont respectivement la valeur maximum et minimum de l'ensemble d'apprentissage pour la composante v , $\pi_{v,i}(x_{k,v}^p)$ est la possibilité d'appartenance de $x_{k,v}^p$ à la classe C_i , et $d(x_{k,v}^p, x_{k,v}^{rej})$ est la distance entre $x_{k,v}^{rej}$ et $x_{k,v}^p$ suivant la composante v , comme illustré sur figure 2.10. Les fonctions d'évolution $f_{v,i}^e$ sont utilisées pour construire une matrice d'évolution.

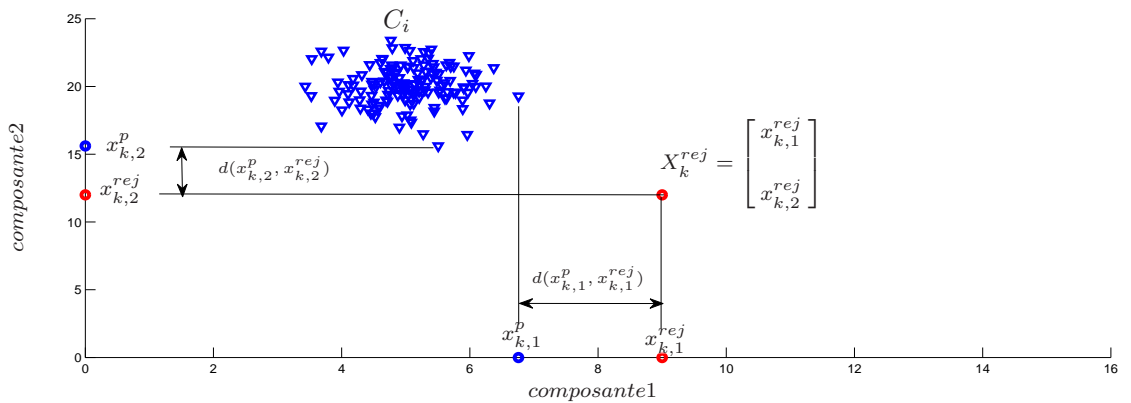


FIGURE 2.10 – Distance $d(x_{k,v}^p, x_{k,v}^{rej})$ pour chaque C_i suivant chaque composante v , avec $D = 2$.

5. Le plus proche voisin $x_{k,v}^{ppv}$ est noté par la suite $x_{k,v}^p$.

► **Matrice et vecteur d'évolution**

La matrice d'évolution M_e est constituée des fonctions d'évolution qui caractérisent la représentativité de l'observation rejetée par rapport à chaque composante et à chaque classe i . La matrice M_e est donnée par la relation suivante :

$$M_e = \begin{pmatrix} f_{1,1}^e & f_{2,1}^e & \cdots & f_{D,1}^e \\ f_{1,2}^e & f_{2,2}^e & \cdots & f_{D,2}^e \\ \vdots & \vdots & \vdots & \vdots \\ f_{1,N_c}^e & f_{2,N_c}^e & \cdots & f_{D,N_c}^e \end{pmatrix}. \quad (2.25)$$

Afin de donner la représentativité de l'observation X_k^{rej} par rapport à chaque classe i pour toutes les composantes v , l'opérateur d'agrégation minimum est utilisé, ce qui donne :

$$f_i^e = \min(f_{1,i}^e, f_{2,i}^e, \dots, f_{D,i}^e). \quad (2.26)$$

La matrice d'évolution M_e devient un vecteur d'évolution V_e de dimension $(N_c \times 1)$ défini par la relation suivante :

$$V_e = \begin{pmatrix} f_1^e \\ f_2^e \\ \vdots \\ f_{N_c}^e \end{pmatrix}. \quad (2.27)$$

L'évolution d'un mode de fonctionnement se caractérise par un chemin de transition entre les modes. Ce chemin est déterminé par une série chronologique d'observations rejetées de N_{rej} échantillons $(X_1^{rej}, \dots, X_{N_{rej}}^{rej})$. L'ensemble V_{c_i} , défini par la relation (2.28), est composé des valeurs d'évolution de N_{rej} observations rejetées permettant de détecter leur évolution par rapport à la classe C_i . L'ensemble V_{c_i} est défini selon la relation suivante.

$$V_{c_i} = \{f_i^e(X_1^{rej}), f_i^e(X_2^{rej}), \dots, f_i^e(X_{N_{rej}}^{rej})\}. \quad (2.28)$$

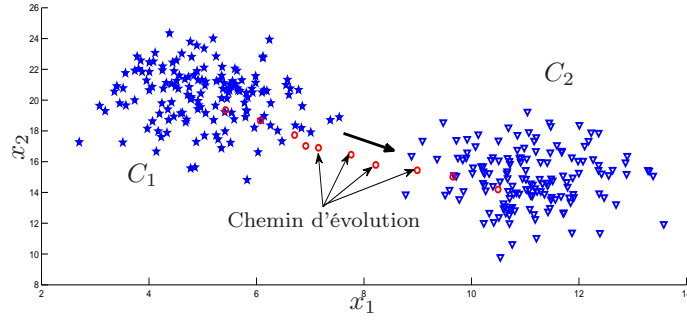

La figure 2.11 représente l'évolution des observations entre la classe C_1 et la classe C_2 . Le passage des observations de C_1 à C_2 se manifeste par la décroissance des f_1^e et la croissance des f_2^e .

La figure 2.12 illustre les trajectoires des courbes de V_{c_1} et V_{c_2} . L'ensemble V_{c_1} décroît lorsque les observations s'éloignent de la classe C_1 et V_{c_2} croît lorsque les observations évoluent en direction de la classe C_2 de la figure 2.11.

► **Détection de l'apparition d'une nouvelle classe**

Pour détecter les évolutions des observations en utilisant la méthode *FPM*, une mesure de la vitesse moyenne de l'évolution des observations a été introduite [68]. La vitesse moyenne V_{m_i} de l'évolution des observations est définie par :

$$V_{m_i} = \frac{1}{N_{rej} - 1} \sum_{l=2}^{N_{rej}} (f_i^e(X_l^{rej}) - f_i^e(X_{l-1}^{rej})). \quad (2.29)$$


 FIGURE 2.11 – Évolution des observations de la classe C_1 vers la classe C_2 .

 FIGURE 2.12 – Décroissance et croissance des f_1^e et f_2^e .

Une valeur négative de V_{m_i} signifie que l'évolution part de la classe i . Une valeur V_{m_i} positive traduit une évolution qui aboutit à la classe i . Un seuil d'évolution S_{e_i} est introduit pour chaque classe i et permet d'indiquer le taux maximum d'observations ayant le même sens d'évolution, c'est-à-dire un éloignement ou un rapprochement. Le seuil d'évolution est calculé dans le but de limiter la sensibilité de la détection au bruit ou aux points aberrants. La valeur de S_{e_i} est donnée par la relation suivante.

$$S_{e_i} = \max(psp_i, psn_i), \quad (2.30)$$

avec

$$psp_i = \frac{1}{N_{rej}-1} \sum_{l=2}^{N_{rej}} (\text{signe}(f_i^e(X_l^{rej}) - f_i^e(X_{l-1}^{rej})) > 0),$$

$$psn_i = \frac{1}{N_{rej}-1} \sum_{l=2}^{N_{rej}} (\text{signe}(f_i^e(X_l^{rej}) - f_i^e(X_{l-1}^{rej})) < 0),$$

avec psp_i le nombre moyen de points positif caractérisant un rapprochement par rapport à la classe i et psn_i représente le nombre de points négatif caractérisant un éloignement par rapport à la classe i . La fonction *signe* permet de déterminer le signe du test à chaque fois qu'il est vrai.

Lorsque cette valeur est égale à 0.5 [68], cela signifie qu'il y a, soit l'apparition d'une nouvelle classe, soit un cas de bruit total, c'est-à-dire que la suite chronologique ne contient que des observations aberrantes. La distinction entre ces deux cas est faite par la vitesse moyenne V_{m_i} qui est beaucoup plus petite en cas d'apparition d'une nouvelle classe [66].

La méthode *FPM* utilise la théorie des possibilités pour prendre en compte à la fois l'imprécision et l'incertitude contenues dans les données. Elle ne nécessite pas une connaissance *a priori* des lois de densité de probabilités. Cependant, elle nécessite une base de connaissance riche permettant de déterminer le nombre de classes contenues dans la base de données et le nombre de barres qui est un paramètre principal de la méthode. Le choix du nombre de barres a une forte influence sur la performance de la méthode *FPM*. Ainsi, si les classes ont des formes complexes et qu'elles sont non séparables par un hyperplan, la méthode *FPM* devient inopérante.

Les nouvelles et anciennes observations ont la même considération par la méthode *FPM*.

2.3.2 Méthode inspirée des k plus proches voisins ($k - ppv$)

La méthode de diagnostic présentée ici est inspirée de la méthode classique des $k - ppv$. Elle a été développée par O. Ondel [80] pour le diagnostic de machines asynchrones. Par comparaison à la version classique de la méthode $k - ppv$, O. Ondel a introduit la notion de création de zones de maillages permettant de réduire le temps de calcul. Il a aussi introduit une technique de classification non exclusive permettant de détecter de nouveaux modes de fonctionnement et de les inclure dans la base de connaissance. Les zones de maillage et la technique de classification non exclusive seront détaillées par la suite.

La méthode $k - ppv$ a pour objectif d'affecter une nouvelle observation X_k recueillie sur le système à la classe majoritairement représentée parmi ses $k - ppv$. La technique la plus simple pour élaborer la règle de décision, consiste à calculer la distance entre la nouvelle observation X_k et chacun des vecteurs de la base de connaissance. Pour cela, différents types de distances peuvent être utilisées pour la règle des $k - ppv$ [81, 23]. La distance la plus exploitée est la distance Euclidienne.

Pour diminuer les erreurs de classification dues à la méthode de $k - ppv$, deux options de rejet ont été introduites dans la version classique améliorée : rejet d'ambiguïté et de distance [23].

2.3.2.1 Rejet d'ambiguïté

La nouvelle observation X_k est rejetée en ambiguïté si le nombre n_k de ses $k - ppv$ issus de chacune des classes de la base de connaissance est inférieur à un nombre minimal fixe k' donné par l'utilisateur. L'observation en rejet d'ambiguïté est classée dans la classe C_{amb} . Ainsi, la nouvelle observation X_k est affectée à la classe C_i si le nombre minimal des $k - ppv$ issus de celle-ci est supérieur à k' . La relation (2.31) résume les deux cas de classement possible cités précédemment.

$$\begin{cases} X_k \in C_i & \text{si } k_i = \max_{l=1, \dots, N_c} (k_l) \geq k', \\ X_k \in C_{amb} & \text{si } k_i = \max_{l=1, \dots, N_c} (k_l) < k', \end{cases} \quad (2.31)$$

avec k_i le nombre de plus proches voisins de X_k (parmi les n_k) appartenant à la classe C_i .

2.3.2.2 Rejet de distance

L'option de rejet de distance est ajoutée à la règle de décision en utilisant un seuil de distance T_i . Le rejet de distance permet de mettre en évidence de nouveaux modes de fonctionnement du système qui étaient absents de la base de connaissance. L'observation X_k est rejetée en distance si et seulement si sa distance par rapport à chacun de ses $k - ppv$ est supérieure au seuil T_i , c'est-à-dire l'observation X_k est associée à la classe C_{dist} . Le seuil T_i peut être défini par :

$$T_i = \beta' \cdot \max_{X_l \in C_i} (d(X_l, M_i)), \quad (2.32)$$

avec M_i le centre de gravité de la classe C_i . Le facteur β' permet de prendre en compte les incertitudes sur la dimension exacte de la classe mais aussi sur le bruit lors de l'acquisition des mesures [80]. Le seuil T_i peut être comparé :

- à la distance moyenne de la nouvelle observation X_k aux observations contenues dans G_r . G_r est un ensemble contenant les $k - ppv$. L'expression est donnée par :

$$X_k \in C_{dist} \text{ si } \frac{1}{n_k} \sum_{X_r \in G_r} d(X_k, X_r) > T_i, \quad (2.33)$$

- ou à la distance entre l'observation X_k et le centre de gravité de la classe C_i , en utilisant la relation suivante.

$$X_k \in C_{dist} \text{ si } d(X_k, M_i) > T_i, \forall i = 1, \dots, N_c. \quad (2.34)$$

La comparaison de T_i à la distance entre l'observation X_k et le centre de gravité M_i de la classe C_i est généralement plus utilisé, car cette expression est plus simple à mettre en œuvre.

Finalement, la règle de $k - ppv$ incluant le rejet d'ambiguïté et le rejet de distance peut s'exprimer par :

$$\begin{cases} X_k \in C_{dist} & \text{si } d(X_k, M_i) > T_i, \text{ pour tout } i = 1, \dots, N_c \\ X_k \in C_{amb} & \text{si } d(X_k, M_i) \leq T_i \text{ et } k_i = \max_{l=1, \dots, N_c} (k_l) < k', \\ X_k \in C_i & \text{si } d(X_k, M_i) \leq T_i \text{ et } k_i = \max_{l=1, \dots, N_c} (k_l) \geq k'. \end{cases} \quad (2.35)$$

Un des inconvénients de la méthode des $k - ppv$ est qu'elle nécessite le calcul des distances entre l'observation X_k de tous les vecteurs de base d'apprentissage et les centre des classes C_i , et leur stockage avant le classement. Cette contrainte pénalise la méthode des $k - ppv$ en termes de temps de calcul si la taille de l'ensemble d'apprentissage initial est grande. Pour cette raison, O. Ondel [80] a proposé une méthode permettant de diminuer le temps de calcul de la règle des $k - ppv$. Cette méthode est basée sur un maillage de l'espace de représentation. Ce maillage de l'espace de représentation est effectué seulement dans les régions où les classes de la base d'apprentissage sont localisées. Des zones de restriction sont définies autour des classes, comme montré sur la figure 2.13. Ainsi ces zones de restriction sont utilisées pour la détection

de nouveaux modes de fonctionnement. Pour déterminer les limites des zones de restriction, la frontière sur chaque axe de l'espace de représentation est donnée par :

$$seuil_i(v) = 2 \times \sigma_i^2(v); v = 1, \dots, D; i = 1, \dots, N_c, \quad (2.36)$$

avec $\sigma_i^2(v)$ variance de la classe C_i sur l'axe v et D la dimension de l'espace de représentation.

L'objectif est de chercher les classes qui sont physiquement proches de la nouvelle observation X_k . Par exemple, sur la figure 2.13, les $k - ppv$ de X_k sont recherchés uniquement entre deux classes C_2 et C_3 au lieu de trois classes.




FIGURE 2.13 – Zones de restriction pour les différentes classes.

Si les distributions des classes sont gaussiennes, une autre méthode de recherche des classes les plus proche de X_k consisterait à calculer la distance entre l'observation X_k et la distribution de chaque classe en utilisant la distance de Mahalanobis.

2.3.2.3 Classification non exclusive

La règle des $k - ppv$ classique exploite une règle de décision exclusive qui utilise une fonction binaire pour associer une nouvelle observation $X_k = [x_{k,1} \dots x_{k,D}]^T$ à l'une des N_c classes de la base de connaissance. En effet, la classification exclusive d'une nouvelle observation peut être effectuée en fonction de la distance entre X_k et la classe C_i , comme défini sur la figure 2.14.a ou en fonction du nombre de voisins, comme illustré à la figure 2.14.b. Ainsi, une classification exclusive affecte X_k à la classe C_i de la même manière qu'en *RdF* classique. Cependant, elle ne permet pas de détecter la transition entre deux classes, ni de suivre l'évolution successive des observations à l'intérieure des classes, c'est-à-dire de donner une mesure de l'évolution du système vis-à-vis des états connus. C'est pour cette raison, que la mise en place d'une règle de décision non exclusive peut être intéressante. Le passage de l'affectation exclusive à l'affectation non exclusive se base sur l'introduction d'une fonction continue et dérivable.

Cette règle de décision non exclusive utilise une fonction d'appartenance graduelle μ pour associer une nouvelle observation X_k à l'une des N_c classes. Le degré d'appartenance $\mu(X_k, C_i)$ doit satisfaire les deux conditions suivantes : être proche de 1 si l'observation X_k appartient à la




FIGURE 2.14 – Classification en fonction : (a) - de la distance, (b) - du nombre de voisins par la règle des $k - ppv$ classique.

classe C_i et tendre vers 0 si l'observation X_k s'éloigne de celle-ci. Elle est généralement établie en fonction de la distance de l'observation X_k à la classe C_i [61], c'est à dire :

$$\mu(X_k, C_i) = f(d(X_k, C_i)).$$

Les règles de décision non exclusive peuvent utiliser la fonction d'appartenance décrite par :

$$\mu(X_k, C_i) = \begin{cases} \left[1 - (1 - \eta_0) \left(\frac{d(X_k, M_i)}{d_{seuil_i}} \right)^g \right] & \text{si } 0 \leq d(X_k, M_i) \leq d_{seuil_i}, \\ \left[\eta_0 \left(\frac{\beta'}{\beta' - 1} \right)^g \left(1 - \frac{d(X_k, M_i)}{\beta' \times d_{seuil_i}} \right)^g \right] & \text{si } d_{seuil_i} < d(X_k, M_i) \leq \beta' \times d_{seuil_i}, \\ 0 & \text{sinon} \end{cases} \quad (2.37)$$

avec $d_{seuil_i} = \max_{X_l \in C_i} (d(X_l, M_i))$ et η_0 un paramètre servant à fixer le "plateau" de la fonction π de la figure 2.15. Le paramètre β' ($\beta' > 1$) permet de définir la largeur de bande de la fonction π , et le paramètre g permet de faire varier la pente de la fonction. M_i est le centre de gravité de la classe C_i .

Sur la figure 2.15, deux niveaux d'appartenance sont déterminés :

- appartenance totale lorsque $d(X_k, M_i) \in [0, d_{seuil_i}]$,
- appartenance graduelle proche d'un modèle gaussien lorsque $d(X_k, M_i) \in]d_{seuil_i}, \beta' d_{seuil_i}]$.

Les règles de décision non exclusives incluent également la notion de rejet en ambiguïté et le rejet en appartenance, c'est-à-dire le rejet en distance dans le cas classique. Pour le rejet en ambiguïté, il est nécessaire que les $k - ppv$ soient issues d'au moins deux classes différentes. Selon la règle de décision non exclusive, une observation est rejetée en ambiguïté si la différence entre les degrés d'appartenance aux classes les plus proches physiquement est inférieure ou égale à un seuil d'ambiguïté S_{amb} [82]. Une observation est rejetée en appartenance si et seulement si son degré d'appartenance à toutes les classes est inférieur à un seuil d'appartenance, noté S_{app} [82]. Finalement, la règle des $k - ppv$ non exclusive incluant les deux options de rejet peut être donnée par :

$$\begin{cases} X_k \in C_i & \text{si } \mu(X_k, C_i) = \max_{c=1, \dots, N_c} (\mu(X_k, C_c)) \text{ et } \mu(X_k, C_i) \geq S_{app}, \\ X_k \in C_{dist} & \text{si } \max_{c=1, \dots, N_c} (\mu(X_k, C_c)) < S_{app}, \\ X_k \in C_{amb} & \text{si } \mu(X_k, C_{i_1}) - \mu(X_k, C_{i_2}) \leq S_{amb}, \end{cases} \quad (2.38)$$

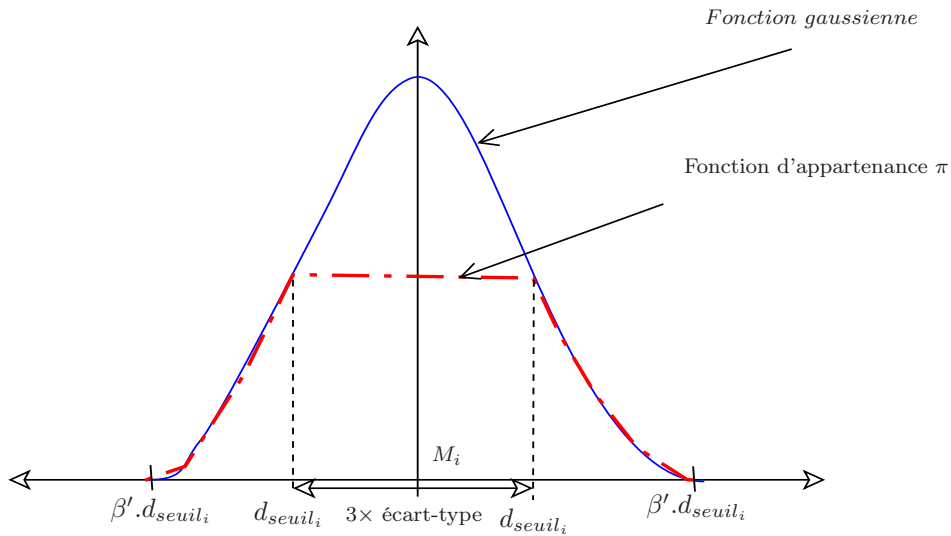


FIGURE 2.15 – Fonction d'appartenance.

avec

$$i_1 = \arg \max_{i=1, \dots, N_c} (\mu(X_k, C_i)) \quad \text{et} \quad i_2 = \arg \max_{i=1, \dots, N_c, i \neq i_1} (\mu(X_k, C_i)).$$

2.3.2.4 Procédure de détection d'une nouvelle classe

Pour déclencher la procédure de détection des nouvelles classes il faut que le nombre des observations rejetées N_{rej} soit supérieur à un certain nombre N_{min} . N_{min} définit le nombre d'observations minimal pour créer une classe. Lorsque le nombre N_{rej} est atteint ($N_{rej} \geq N_{min}$), des ensembles de N_{min} observations sont extraits par des permutations circulaires. Ainsi, pour chaque groupe extrait, la compacité C_r est calculée. La compacité C_r est comparée à la compacité moyenne C_m de l'ensemble des classes existantes donné par :

$$C_m = \frac{1}{N_c} \frac{1}{N} \sum_{i=1}^{N_c} \sum_{X_l \in C_i} (X_l - M_i)(X_l - M_i)^T, \quad (2.39)$$

avec N nombre d'échantillons total et N_i le nombre d'échantillons appartenant à la classe C_i .

Lorsqu'une observation est rejetée par la règle de décision, une zone de restriction Z_i , dont la dimension est déterminée à partir de la dispersion moyenne C_m des classes existantes, comme illustré sur la figure 2.16. L'apparition d'une nouvelle classe est confirmée si et seulement si l'ensemble des observations affectées à la zone Z_j est supérieure à N_{min} et $C_r < 1,5 \times C_m$ [81].

L'algorithme des $k - ppv$ a l'avantage d'être facile à programmer et à implémenter. Mais son utilisation nécessite beaucoup de paramètres à définir par l'utilisateur. L'algorithme nécessite également un grand nombre de données d'apprentissage qui requiert des ressources de mémoires élevées et un temps d'exécution important. La nécessité de disposer d'un grand nombre d'échantillons, rend le processus de décision complexe. Ainsi la mise en œuvre de cette méthode nécessite

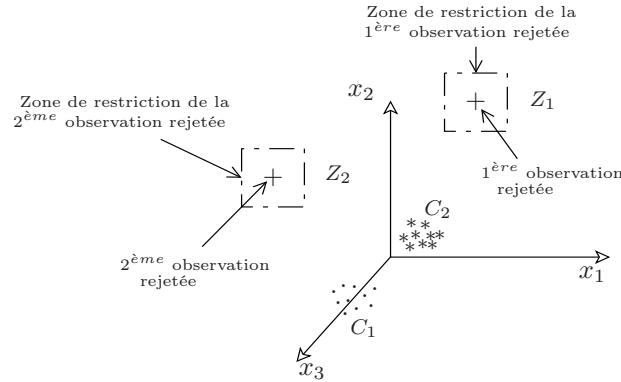


FIGURE 2.16 – Représentation de la 1^{ère} et de la 2^{ème} observations rejetées ainsi que leur zone de restriction respective.

une connaissance *a priori* sur les modes de fonctionnement du processus. Par exemple, la détermination de $k - ppv$ nécessite le calcul d'un nombre de distances toujours croissant.

Notons enfin que la méthode $k - ppv$ a été adaptée pour détecter des nouveaux modes de fonctionnement, mais elle n'est pas adaptée pour suivre l'évolution des modes existants.

2.3.3 Méthode LAMDA

2.3.3.1 Description de LAMDA

La méthode *LAMDA* (Learning Algorithm for Multivariable Data Analysis) est une méthode de classification basée sur la logique floue. Elle permet de représenter les modes de fonctionnement d'un processus sous forme de classes C_1, \dots, C_{N_c} .

Dans la méthode de classification *LAMDA*, la notion de fonction d'appartenance est remplacée par le Degré d'Adéquation Marginale, noté *DAM*. Le degré *DAM* est obtenu à partir de l'analyse des contributions de chacune des composantes de l'observation X_k aux caractéristiques des classes. Plusieurs types de fonctions de *DAM* peuvent être utilisés [26], parmi lesquelles nous trouvons la fonction binomiale floue. Cette fonction est une estimation bayésienne non paramétrique, c'est-à-dire il n'y a pas une distribution de probabilité imposée [48]. L'expression du *DAM* de chaque composante du vecteur d'observation X_k est donnée par :

$$\left\{ \begin{array}{l} DAM_{v,i}(x_{k,v}, \rho_{v,i}) = \rho_{v,i}^{\hat{x}_{k,v}} \times (1 - \rho_{v,i})^{1 - \hat{x}_{k,v}}, \\ \hat{x}_{k,v} = \frac{x_{k,v} - x_{\min,v}}{x_{\max,v} - x_{\min,v}}, \text{ avec } x_{\max,v} = \max_{k=1, \dots, N_i} (x_{k,v}) \text{ et } x_{\min,v} = \min_{k=1, \dots, N_i} (x_{k,v}), \\ \rho_{v,i}(\hat{x}_{k,v}/C_i) = \frac{1}{Card(C_i)} \sum_{\hat{x}_{k,v} \in C_i} \hat{x}_{k,v}; \quad v = 1, \dots, D; \quad i = 1, \dots, N_c, \end{array} \right. \quad (2.40)$$

où $x_{k,v}$ et $\hat{x}_{k,v}$ désignent respectivement la valeur brute et la valeur normalisée suivant la composante v de l'observation X_k , $\rho_{v,i}$ est la probabilité qu'une observation X_k appartenant à la classe C_i ait la valeur de présence de la composante égale à $\hat{x}_{k,v}$, $x_{\max,v}$ et $x_{\min,v}$ sont respectivement la valeur maximale et minimale de chaque composante.

Une fois que tous les DAM sont calculés, le Degré de l'Adéquation Global (DAG) de l'observation X_k à une classe donnée est déterminé en utilisant des opérateurs logiques d'agrégation. Un opérateur produit ou max peut être utilisé pour déterminer à partir des DAM , le DAG de chaque classe contenue dans la base de connaissance. L'expression du DAG utilisant l'opérateur produit est donnée selon la relation suivante :

$$DAG_i(X_k, C_i) = \prod_{v=1}^D (DAM_{v,i}), \quad (2.41)$$

$$X_k \in C_i \text{ tel que } i = \arg \max(DAG_1(X_k, C_1), \dots, DAG_{N_c}(X_k, C_{N_c})).$$

La figure 2.17 illustre l'architecture de la méthode $LAMDA$.

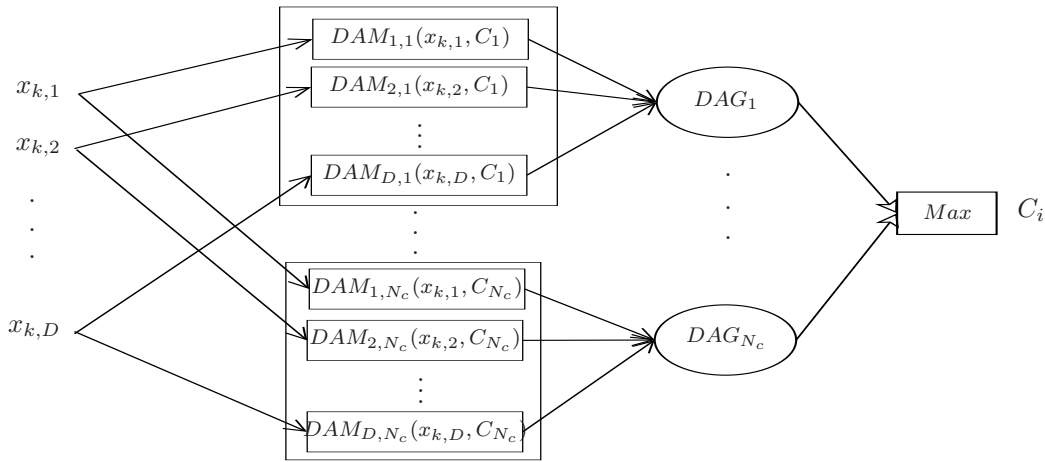


FIGURE 2.17 – Architecture de réseau $LAMDA$.

2.3.3.2 Procédure de détection d'une nouvelle classe

Afin de détecter l'apparition d'une nouvelle classe, la méthode de classification $LAMDA$ utilise un seuil minimum de DAG , au-dessous duquel il y a rejet. Cela permet d'éviter l'affectation d'une observation peu représentative à une classe de la base de connaissance. Ce seuil correspond au DAG obtenu pour la Classe Non-Informative (NIC). Cette classe a la particularité d'accepter toutes les observations de l'espace de description avec le même DAG . Son $\rho_{v,NIC}$ est égal à $\frac{1}{2}$ pour toutes les composantes. Cette classe est très importante pour le processus de formation d'une nouvelle classe [67].

Si le DAG de la nouvelle observation est inférieur à DAG_{NIC} pour toutes les classes connues, l'observation X_k est attribuée à la classe NIC . Elle est le premier élément d'une nouvelle classe C_{N_c+1} , avec N_c le nombre de classes à l'instant précédent. La représentation de la nouvelle classe dépendra de l'observation X_k . Les paramètres de la nouvelle classe sont obtenus en modifiant les paramètres de la classe NIC à partir de la relation suivante :

$$\rho_{v,q} \leftarrow 0.5 + \frac{(\hat{x}_{k,v} - 0.5)}{N_0 + 1}, \quad q = N_c + 1, \quad (2.42)$$

avec $N_0 > 0$ un paramètre fictif correspondant au « nombre d'éléments de la classe vide » [67]. Le paramètre N_0 détermine l'initialisation de l'apprentissage.

Lorsque la nouvelle observation X_k est affectée à la classe i , les paramètres de cette classe sont mis à jour à partir de la relation suivante.

$$\rho_{v,i} \leftarrow \rho_{v,i} + \frac{(\hat{x}_{k,v} - \rho_{v,i})}{N_i + 1}, \quad (2.43)$$

avec N_i le nombre d'observations associées à la classe C_i à l'instant précédent.

La figure 2.18 représente un exemple d'affectation ou de création d'une nouvelle classe par la méthode *LAMDA*. Nous voyons sur la figure 2.18.c que le *DAG* maximum ($DAG = 0.125$) de la nouvelle observation est égal au *DAG* de la classe *NIC*, ce qui déclenche la création d'une 4^{ème} classe dont la première observation classée dans celle-ci est X_k .

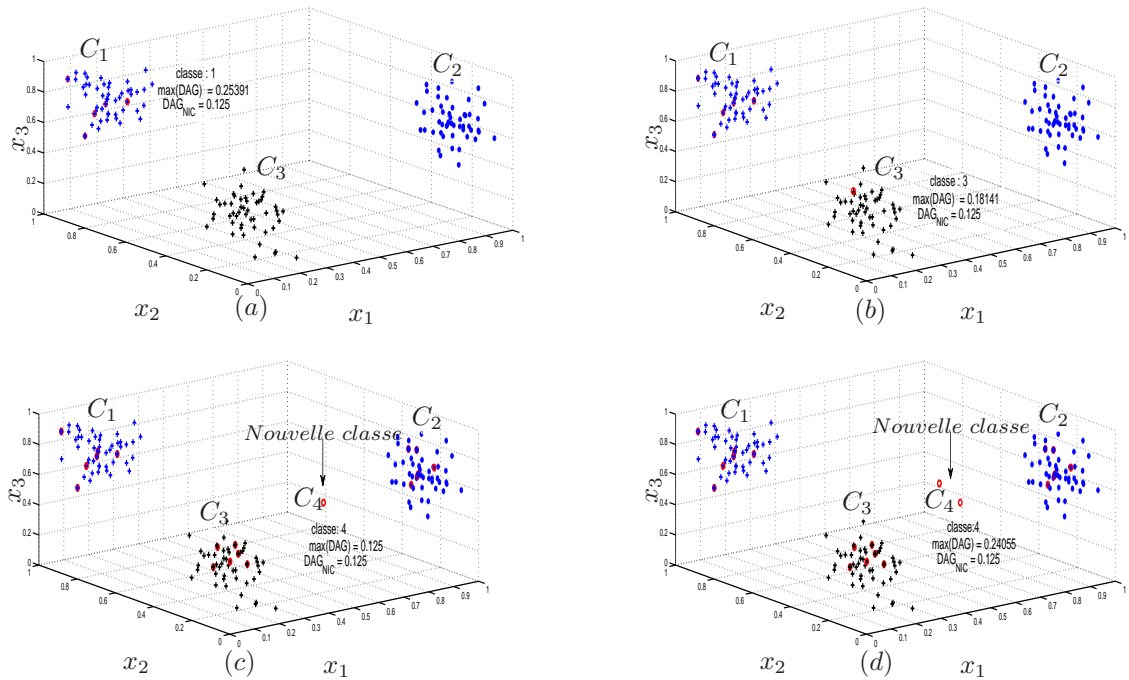


FIGURE 2.18 – Illustration de la classification par la méthode *LAMDA*, (a) - association de X_k à C_1 , (b) - association de X_{k+1} à C_3 , (c) - création d'une nouvelle classe C_4 et (d) - association de X_{k+2} à C_4 .

La méthode de *LAMDA* a l'avantage d'être une méthode de classification qui peut être supervisée ou non (auto-apprentissage). Mais l'inconvénient de cette méthode est qu'elle ne prend pas en compte la complexité des formes des classes dans la modélisation. Chaque classe, quelle que soit sa forme ne peut être modélisée que par un seul prototype.

A cause de la non exhaustivité des modes de fonctionnement et du comportement évolutif des systèmes réels, il est nécessaire pour un processus de supervision de pouvoir identifier l'apparition

de nouveaux modes de fonctionnement, puis de les intégrer dans la base de connaissance. Ainsi, l'outil de modélisation doit être capable :

- de modéliser des classes de formes complexes et d'adapter les modes de fonctionnement lorsqu'ils évoluent au cours du temps,
- de fusionner des classes lorsqu'un nombre d'ambiguïté est atteint,
- d'éliminer des classes peu représentatives de la base de connaissance.

Les méthodes citées précédemment ne permettent pas de vérifier l'ensemble des conditions énumérées pour un outil de modélisation de systèmes évolutifs. Les méthodes *FPM* et *k - ppv* ne sont pas adaptées pour suivre des classes dynamiques et pour détecter l'évolution des modes de fonctionnement. Et la méthode *LAMDA* n'est pas capable de suivre des classes dynamiques et ne permet pas de modéliser des classes de formes complexes. Afin de combler ces lacunes, un algorithme de classification dynamique de données évolutives est présenté dans la section suivante.


2.4 Classifieur *AUDyC*

L'*AUDyC* (AUto-adaptive and Dynamical Clustering) est un algorithme de classification dynamique de données évolutives. Il est basé sur un réseau de neurones à architecture évolutive permettant de modéliser les modes de fonctionnement du procédé par des classes caractérisées par un ou plusieurs prototypes. Les prototypes sont adaptés en continu, ce qui permet d'actualiser la base de connaissance en y intégrant rapidement l'occurrence d'un nouveau mode de fonctionnement. La fusion des classes ou des prototypes est réalisée en fonction d'un seuil d'ambiguïté prédéfini. L'un des avantages de ce classifieur réside dans le fait qu'il n'est pas nécessaire de disposer d'une connaissance *a priori* sur les modes de fonctionnement du procédé. De plus, ce classifieur a la capacité à modéliser des classes de forme complexe. L'*AUDyC* utilise un mode d'apprentissage continu sur une fenêtre glissante, ce qui permet de limiter l'influence des anciennes informations dans la modélisation, c'est-à-dire qu'il peut potentiellement oublier les informations les plus anciennes, devenues non représentatives.

2.4.1 Présentation générale de l'algorithme *AUDyC*

L'*AUDyC* est un algorithme de classification de données évolutives basé sur une technique de modélisation inspirée du modèle de mélange gaussien [59]. La structure de l'*AUDyC* est organisée en trois couches, comme montré sur la figure 2.19 : une couche d'entrée, une couche cachée et une couche de sortie.

- La couche d'entrée contient autant de neurones que de composantes au sein du vecteur d'observation $X_k = [x_{k,1} \cdots x_{k,l} \cdots x_{k,D}]^\top$.
- La couche cachée contient autant de neurones que de prototypes existants à chaque instant. Sur cette couche, chaque prototype est caractérisé par un neurone. La fonction d'activation du neurone j traduit la fonction d'appartenance μ_j des observations au prototype P_j . Ainsi,

FIGURE 2.19 – Architecture du réseau *AUDyC*.

le terme $\mu(X_k, P_j)$ exprime le degré d'appartenance de l'observation X_k au prototype P_j . Le degré d'appartenance $\mu(X_k, P_j)$ est donné par la relation suivante.

$$\mu_j = \mu(X_k, P_j) = \exp \left(- \frac{(X_k - M_{P_j}) \Sigma_{P_j}^{-1} (X_k - M_{P_j})^\top}{2} \right), \quad (2.44)$$

où M_{P_j} et $\Sigma_{P_j}^{-1}$ désignent respectivement le centre et l'inverse de la matrice de covariance du prototype P_j .

Le choix de la relation (2.44) comme fonction d'activation correspond à la définition de prototypes gaussiens [58]. Pour classer ou rejeter une nouvelle observation, l'*AUDyC* utilise deux seuils d'appartenance, notés μ_{\min} et μ_{\max} avec lesquels seront comparés les degrés d'appartenance de la nouvelle observation aux différents prototypes N_P et classes N_C . Les deux seuils d'appartenance sont illustrés sur la figure 2.20. Le seuil μ_{\min} peut être interprété comme le seuil minimum d'appartenance d'une observation à une classe C_i . Le seuil μ_{\max} peut être interprété comme le seuil minimum d'appartenance d'une observation à un prototype P_j . Si le degré d'appartenance $\mu(X_k, P_j)$ de la nouvelle observation $X_k = [x_{k,1} \cdots x_{k,D}]^\top$ au prototype P_j est supérieur à μ_{\min} , alors l'observation est affectée à la classe à laquelle est associée le prototype P_j , dans ce cas de figure, les caractéristique de P_j ne sont pas pas adaptées. Si $\mu(X_k, P_j)$ est supérieur à μ_{\max} , alors l'observation X_k est associée à la classe du prototype P_j et contribue à sa définition.

Les coordonnées des centres des prototypes de la couche cachée sont mémorisées dans la matrice $W^P = [w_{jd}^P]_{j \in [1, \dots, N_p]; d \in [1, \dots, D]}$. Le nombre de prototypes N_p dans cette couche est évolutif, c'est-à-dire que leur nombre n'est pas figé.

- La couche de sortie comporte autant de neurones que de classes. Les connexions entre les neurones de la couche de sortie et ceux de la couche cachée définissent les appartenances des prototypes P_j aux classes. Les connexions entre les prototypes et les classes sont mémorisées dans la matrice binaire $W^C = W_{ij}^C$ de dimension $N_c \times N_p$, avec N_c la dimension de la couche de sortie. Le nombre des classes est évolutif. L'association d'un prototype P_j à la classe C_i




FIGURE 2.20 – Prototype gaussien avec sa région d'influence hyperelliptique et sa fonction d'appartenance gaussienne.

se traduit par l'égalité $W_{ij}^C = 1$ et sinon $W_{ij}^C = 0$. La sortie de chaque neurone de la couche de sortie donne le degré d'appartenance du vecteur d'entrée X_k à la classe correspondante C_i . Le degré d'appartenance $\psi(X_k, C_i)$ du vecteur d'entrée à la classe C_i peut être calculé en utilisant l'opérateur de type t-norme (max, somme bornée, ...) selon la relation suivante.


$$\left\{ \begin{array}{l} \psi(X_k, C_i) = \max_{l=1, \dots, N_{P_i}} (\mu(X_k, P_l)), \quad \text{avec } P_l \in C_i, \\ \text{ou} \\ \psi(X_k, C_i) = \min \left[1, \sum_{P_j \in C_i} (\mu(X_k, P_j)) \right]. \end{array} \right. \quad (2.45)$$

Les règles permettant au classifieur dynamique *AUDyC* de répondre à toutes les exigences énoncées précédemment seront présentées par la suite.

2.4.2 Règles d'apprentissage

La figure 2.21 représente le processus d'apprentissage du réseau *AUDyC* réalisé en continu. Le processus d'apprentissage de l'*AUDyC* présente trois types de règles : la règle de classification, la règle de fusion et la règle d'évaluation. Les règles de classification permettent de classer ou de rejeter toute nouvelle observation X_k [59].

Les caractéristiques d'un prototype P_j , c'est-à-dire le centre M_{P_j} et la matrice de covariance Σ_{P_j} , sont adaptées lorsque l'observation X_k lui est associée. Ces caractéristiques sont mises à jour en utilisant les équations récursives permettant à la fois d'ajouter des nouvelles informations et d'oublier des anciennes informations sur une fenêtre glissante de largeur N_{fen} . Les caractéristiques des prototypes sont mises à jour de la manière suivante : si le cardinal du prototype P_j , noté n_{P_j} est inférieur à N_{fen} , les caractéristiques du prototype P_j sont adaptées en ajoutant des


 FIGURE 2.21 – Processus d'apprentissage en ligne du réseau *AUDyC*.

nouveautés. Les caractéristiques de P_j sont adaptées par la relation suivante :

$$\begin{cases} M_{P_j}(k) = \frac{n_{P_j}}{n_{P_j} + 1} M_{P_j}(k-1) + \frac{1}{n_{P_j} + 1} X_k, \\ \Sigma_{P_j}(k) = \frac{n_{P_j} - 1}{n_{P_j}} \Sigma_{P_j}(k-1) + \frac{1}{n_{P_j} + 1} (X_k - M_{P_j}(k-1))(X_k - M_{P_j}(k-1))^{\top}. \end{cases} \quad (2.46)$$

Dans le cas contraire, les paramètres du prototype P_j sont adaptés par ajout des nouveautés et suppression d'anciennes informations, selon la relation suivante.

$$\begin{cases} M_{P_j}(k) = M_{P_j}(k-1) + \frac{1}{N_{fen}} (\delta X^+ - \delta X^-), \\ \Sigma_{P_j}(k) = \Sigma_{P_j}(k-1) + \Delta X \begin{bmatrix} \frac{1}{N_{fen}} & \frac{1}{N_{fen}(N_{fen}-1)} \\ \frac{1}{N_{fen}(N_{fen}-1)} & -\frac{(N_{fen}+1)}{N_{fen}(N_{fen}-1)} \end{bmatrix} \Delta X^{\top}, \end{cases} \quad (2.47)$$

où

$$\begin{cases} \delta X^+ = X_k - M_{P_j}(k-1), \\ \delta X^- = X_{old} - M_{P_j}(k-1), \\ \Delta X = [\delta X^+ \quad \delta X^-], \end{cases}$$

avec $M_{P_j}(k)$ et $\Sigma_{P_j}(k)$ respectivement le centre et la matrice de covariance du prototype P_j à l'instant k .

X_{old} : observation la plus ancienne dans la fenêtre,

La largeur de la fenêtre glissante est un paramètre de réglage de l'algorithme *AUDyC*. Pour effectuer un bon réglage de N_{fen} , un compromis entre le poids de la nouvelle observation par rapport aux anciennes observations, ainsi qu'avec la sensibilité du modèle aux nouvelles observations doit être trouvé. Si N_{fen} est grand, le poids de chaque nouvelle observation sera faible par rapport au reste de la population. Le modèle est alors plus stable. Si N_{fen} est petit, le modèle devient très sensible aux nouvelles observations, ainsi qu'au bruit [9]. Ainsi, le choix doit être effectué en prenant en compte les dynamiques d'évolution qui seront recherchées.

Sur la figure 2.21, un ensemble d'observations en situation d'ambiguïté \mathbb{X}_{amb} est défini, ainsi qu'un ensemble des observations classées \mathbb{X}_{cl} . Les observations contenues dans l'ensemble \mathbb{X}_{amb} sont exploitées pour fusionner des classes et/ou des prototypes. Les règles d'évaluation ont pour

rôle d'évaluer les prototypes qui doivent être conservés ou éliminés. Les données des prototypes éliminés sont conservées dans l'ensemble \mathbb{X}_{app} . L'ensemble du processus d'apprentissage est décrit dans les parties suivantes.

2.4.2.1 Phase de classification

La phase de classification a pour objectif de définir et d'adapter l'architecture du réseau *AUDyC* afin d'optimiser la modélisation des classes en fonction des observations présentées. La particularité de cette première phase se situe dans la capacité de l'*AUDyC* à adapter les paramètres des prototypes existants et/ou à créer des prototypes et/ou classes. La création de nouveaux prototypes se caractérise par l'apparition de nouveaux neurones dans la couche cachée. De plus, de nouveaux neurones sont créés dans la couche de sortie lorsque de nouvelles classes apparaissent. Pour chaque nouvelle observation X_k présentée à l'entrée du réseau, ses degrés d'appartenance $\mu(X_k, P_j)$ aux différents prototypes P_j connus sont évalués. La comparaison de $\mu(X_k, P_j)$ aux seuils μ_{\min} et μ_{\max} donne les différentes situations d'apprentissage présentées sur le tableau 2.1 [52].

	Situation	Règles d'évolution
Cas 1	Le degré de similarité entre X_k et n'importe quel prototype connu est inférieur au seuil minimum μ_{\min} , $(\mu(X_k, P_j) < \mu_{\min})$.	X_k n'est proche d'aucun prototype. Il est nécessaire de créer un nouveau prototype (un nouveau neurone sur la couche cachée) et une nouvelle classe (un nouveau neurone sur la couche de sortie).
Cas 2	Le degré d'appartenance est supérieur au premier seuil μ_{\min} mais inférieur au seuil μ_{\max} pour plusieurs prototypes appartenant à la même classe, $\mu_{\min} < \mu(X_k, P_j) < \mu_{\max}$.	L'observation X_k est proche de plusieurs prototypes P_j de la même classe mais pas suffisamment près. Il est nécessaire de créer un nouveau prototype. Ce nouveau prototype P'_j est associé à la classe C_i .
Cas 3	Le degré d'appartenance est supérieur aux deux seuils pour plusieurs prototypes appartenant à la même classe, $\mu_{\min} < \mu_{\max} < \mu(X_k, P_j)$.	L'observation X_k est associée au prototype P_j le plus proche. Le prototype P_j est adapté en modifiant son vecteur moyen et sa matrice de covariance, cf : (2.46) ou (2.47).
Cas 4	Le degré d'appartenance est supérieur au premier seuil μ_{\min} pour plusieurs prototypes appartenant à différentes classes, $\mu_{\min} < \mu(X_k, P_j)$.	L'observation X_k est en situation d'ambiguïté. Cette ambiguïté va être analysée lors de l'étape de fusion de la procédure d'apprentissage.
Cas 5	Périodiquement, toutes les \mathcal{L} nouvelles observations, les cardinalités des P_j et des C_i sont évaluées.	Si durant les \mathcal{L} dernières observations, aucune observation n'est associée à la nouvelle classe créée, alors elle est éliminée.

TABLE 2.1 – Règles d'évolution du réseau *AUDyC*.

La figure 2.22 représente un exemple d'initiation d'apprentissage par le réseau *AUDyC* et de modélisation des classes par plusieurs prototypes. La première observation $X_1 = [x_{1,1} \ x_{1,2}]^\top$ donne lieu à la définition de la première classe C_1 caractérisée par un seul prototype P_1 (cas 1 du tableau 2.1). La figure 2.23 représente deux classes C_1 et C_2 caractérisées chacune par un prototype à l'instant k . A l'instant $k + n$, les classes C_1 et C_2 sont respectivement caractérisées par trois et deux prototypes, comme montré sur la figure 2.24.




FIGURE 2.22 – Création du premier neurone de la couche cachée et de la couche de sortie.




FIGURE 2.23 – Exemple de deux classes constituées de deux prototypes respectivement.




FIGURE 2.24 – Exemple de deux classes constituées de deux et trois prototypes respectivement.

2.4.2.2 Phase de fusion

La phase de classification a permis d'élaborer une structure de classes en créant un ensemble de prototypes caractérisant les différentes classes [58]. A l'issue de cette phase, certaines observations peuvent présenter une ambiguïté d'appartenance vis-à-vis de plusieurs classes ou plusieurs prototypes (*voir* figure 2.25.a). Les observations en ambiguïté d'appartenance sont associées à l'ensemble \mathbb{X}_{amb} . L'observation X_k est en ambiguïté d'appartenance vis-à-vis de la classe C_i et de la classe $C_{i'}$, si et seulement si $X_k \in C_i$ et $X_k \in C_{i'}$:

$$X_k \in C_i \text{ et } X_k \in C_{i'} \Rightarrow X_k \in \mathbb{X}_{amb}. \quad (2.48)$$

Une phase de fusion a été élaborée pour gérer ces situations d'ambiguïté afin d'améliorer le processus d'apprentissage [58]. Cette procédure consiste à introduire un nouveau critère d'acceptation basé sur le nombre d'observations ambiguës, noté n_{amb} . Les classes C_i et $C_{i'}$ sont fusionnées si le cardinal de l'ensemble \mathbb{X}_{amb} est supérieur à un seuil d'ambiguïté n_{amb} , c'est-à-dire $Card(\mathbb{X}_{amb}) > n_{amb}$. Par exemple avec un nombre $n_{amb}=1$, les classes C_1 et C_2 de la figure 2.25.a sont fusionnées comme le montre la figure 2.25.b.

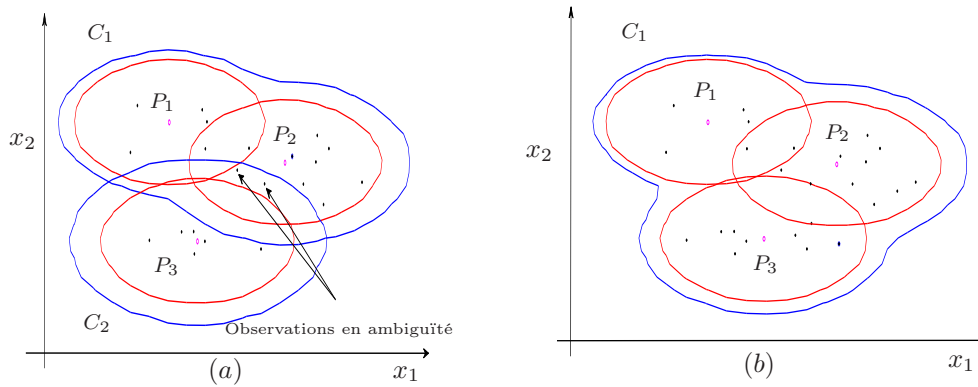


FIGURE 2.25 – Procédure de fusion, (a) - Classes en ambiguïté, (b) - fusion de la classe C_1 et C_2 , avec $n_{amb} = 1$.

2.4.2.3 Phase d'évaluation

La phase d'évaluation est importante pour éliminer les prototypes et classes parasites éventuellement créés par l'influence du bruit [64]. Cette phase est basée sur la cardinalité des prototypes et des classes pour détecter les modes non représentatifs. Le cardinal d'une classe est égal à la somme des cardinaux des différents prototypes appartenant à cette classe.

En considérant \mathcal{L} acquisitions d'observations, la cardinalité des prototypes et des classes sont évaluées puis comparées respectivement à deux seuils, notés $N_{C_{min}}$ et $N_{P_{min}}$. $N_{P_{min}}$ et $N_{C_{min}}$ sont respectivement le cardinal minimal que doit avoir un prototype et une classe pendant la phase d'évaluation pour ne pas être éliminés. Le nombre d'échantillons \mathcal{L} doit être choisie en fonction du nombre de points $N_{C_{min}}$.

2.4.3 Procédures de création et de suivi d'évolution des classes par *AUDyC*

L'*AUDyC* est une architecture auto-adaptative. Avec l'algorithme *AUDyC*, les modes sont créés et éliminés facilement par la création et l'élimination de neurones. Cet algorithme est un classifieur non supervisé, donc il ne nécessite pas une *a priori* sur les modèles. Ces derniers sont appris (créés et adaptés) en ligne.

2.4.3.1 Création des classes par l'algorithme *AUDyC*

L'algorithme *AUDyC* modélise les classes à partir des observations qui lui sont présentées. Les classes sont constituées à partir d'assemblage de modèles de mélanges gaussiens [58, 10]. Chaque gaussienne est caractérisée par un centre M_{P_j} et une matrice de covariance Σ_{P_j} . A chaque fois qu'une nouvelle observation X_k est présentée au réseau *AUDyC*, son degré de similarité $\mu(X_k, P_j)$ entre les différentes gaussiennes connues est calculée. Lorsque le degré de similarité $\mu(X_k, P_j)$ est inférieur au seuil minimum μ_{\min} , l'*AUDyC* crée une nouvelle classe caractérisée par un nouveau prototype.

La figure 2.26.a illustre le rejet en distance de l'observation X_k par rapport à la classe C_1 et la figure 2.26.b illustre la création d'une nouvelle classe C_2 par *AUDyC*. Les caractéristiques de la nouvelle classe C_2 sont : $M_{P_2} = X_k$ et $\Sigma_{P_2} = \sigma_{init}I$, la valeur de σ_{init} est donnée par l'expert du système et I une matrice identité.




FIGURE 2.26 – Procédure de création de classes par *AUDyC*, (a) - rejet en distance de X_k par rapport à la classe C_1 , (b) - création d'une nouvelle classe C_2 .

2.4.3.2 Suivi des classes évolutives par l'algorithme *AUDyC*

L'*AUDyC* est un algorithme de classification dynamique de données évolutives permettant une modélisation dynamique des classes au fur et à mesure de la présentation de nouvelles observations. Il intègre des capacités d'auto-adaptation autorisant l'évolution des modèles des classes existantes. Lorsque les observations évoluent lentement, les classes s'adaptent et vont suivre les observations. La figure 2.27 illustre le suivi d'un modèle de classe par l'algorithme *AUDyC*.

L'intérêt de l'algorithme de classification dynamique de données évolutives *AUDyC* réside dans sa capacité à modéliser à chaque instant k l'espace de décision évoluant au cours du temps en

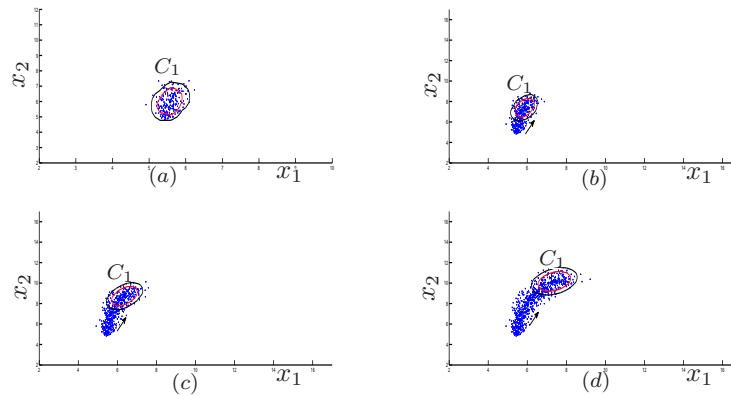


FIGURE 2.27 – Suivi des modes de fonctionnement par l'algorithme *AUDyC*, (a) - classe C_1 à l'instant k , (b) - classe C_1 à l'instant $k + k_1$, (c) - classe C_1 à l'instant $k + k_2$ ($k_2 > k_1$) et (d) - classe C_1 à l'instant $k + k_n$ ($k_n > k_2$).

tenant compte de l'évolution de la distribution des données. L'algorithme *AUDyC* a la capacité de détecter l'apparition de nouveaux modes de fonctionnement, puis de les inclure dans la base de connaissance. Cet algorithme a également la capacité d'adapter en temps réel les caractéristiques des modes de fonctionnement lorsqu'elles évoluent au cours du temps.

Cette connaissance en temps réel de l'état de fonctionnement du procédé ou de ses composants est utilisée pour pronostiquer leurs états futurs afin d'anticiper les défauts ou les défaillances du procédé. Le pronostic de défaillance de systèmes évolutifs est présenté dans le chapitre suivant.

2.5 Conclusion

Dans ce chapitre, nous avons montré l'intérêt d'utiliser les techniques de reconnaissance de formes floues pour le diagnostic de systèmes dynamiques évolutifs. Il a été également montré l'avantage d'utiliser les méthodes de diagnostic adaptatif, telles que la méthode *FPM* (Fuzzy Pattern Matching), la méthode des k -plus proches voisins améliorée, la méthode *LAMDA* (Learning Algorithm for Multivariate Data Analysis) et l'algorithme *AUDyC* (AUto-adaptative and Dynamical Clustering). Parmi ces méthodes de diagnostic, seul l'algorithme *AUDyC* répond aux critères de classification dynamique des données évolutives que nous nous sommes fixés. L'algorithme *AUDyC* est capable de modéliser finement les données évolutives en les regroupant dans des classes de forme complexe. Cette capacité est obtenue par la définition d'un module d'apprentissage en ligne et accompagnée d'une nouvelle définition des prototypes et des classes afin d'améliorer la qualité de la modélisation dynamique. L'apprentissage continu du réseau *AUDyC* s'appuie à la fois sur les capacités d'auto-adaptation de l'architecture du réseau et sur la présentation continue de données au réseau. L'arrivée de données en continu permet de définir une étape d'apprentissage en ligne où les données sont présentées successivement au réseau.

La structure de l'*AUDyC* et l'espace dynamique qu'il crée permettent d'élaborer des mesures de détection de changement de comportement du procédé, suivi des évolutions, ainsi de

rapprochement/éloignement entre les classes. Vu le comportement généralement évolutif des processus industriels, les outils de supervision utilisés doivent être adaptatifs afin de pouvoir suivre les modes de fonctionnement existant et de détecter l'apparition des nouveaux modes de fonctionnement. Le suivi en continu de l'évolution de la dégradation des processus industriels et de la prévision des défaillances et leur caractérisation, permet de planifier de façon efficiente des actions de maintenance prévisionnelle.

Les outils de détection de changement de comportement du procédé et la prévision de la situation future des classes correspond aux modes de fonctionnement du procédé sont présentés dans le chapitre 3.

3

Pronostic de défaillance de systèmes évolutifs

3.1 Introduction

Le pronostic de défaillance est aujourd'hui considéré comme un processus clé dans les stratégies de maintenance préventive, grâce à sa fonction d'anticipation [101]. C'est la raison pour laquelle les scientifiques et les industriels accordent une importance croissante au développement d'outils de pronostic de défaillance [62]. Après la détection de la dégradation, le rôle du pronostic est de prédire l'état futur du procédé ou de ses composants sur un horizon de temps donné à partir de son état courant. Le pronostic de défaillance est l'estimation ou la prédiction de la durée de vie résiduelle appelée *RUL* (Remaining Useful Life) d'un procédé ou de ses composants, c'est-à-dire la durée au bout de laquelle le composant ou le procédé ne pourra plus exercer sa fonction avec succès [57, 96, 4, 75, 38]. En terme probabiliste, le pronostic de défaillance consiste à estimer la probabilité qu'une défaillance survienne à un instant futur donné [62, 72, 101]. Dans la littérature, il existe trois catégories d'approches de pronostic [34, 20] : approches de pronostic basées sur un modèle physique, approches de pronostic guidées par les données et approches de pronostic basées sur les données de retour d'expérience.

Dans notre cas, les indicateurs de dégradation sur lesquels s'appuie notre outil de pronostic sont obtenus par des métriques sur les évolutions des caractéristiques des modes de fonctionnement. Ces caractéristiques sont déterminées en continu par l'algorithme de classification dynamique présenté dans la section 2.4 (chapitre 1). Les indicateurs de dégradation obtenus par la combinaison de l'algorithme de classification dynamique et des méthodes d'analyse de défaillance peuvent être considérés comme des probabilités d'occurrence de défaillance⁶. Ces probabilités

6. Une défaillance correspond à une cessation de l'aptitude d'une entité à accomplir une ou plusieurs fonctions

obtenues en temps réel sont utilisées pour temporiser et probabiliser l'arbre de défaillance du procédé, c'est-à-dire obtenir un arbre de défaillance dont les probabilités des événements évoluent au cours du temps. Le processus de pronostic s'appuiera sur ces probabilités pour estimer la probabilité qu'une défaillance survienne à un instant futur donné. Le pronostic en temps réel permet alors d'adapter les opérations de maintenance prévisionnelle aux états futurs du système.

Les outils de détection de dérives sont présentés dans la section 3.2. Dans la section 3.3, les indicateurs de dégradation sont présentés. Ensuite, les méthodes d'analyse de défaillance les plus répandues dans le milieu industriel sont présentées dans la section 3.4. Les différentes approches de pronostic ainsi que leurs avantages et inconvénients sont présentés dans la section 3.5. Enfin, notre proposition pour le pronostic de défaillance de systèmes évolutifs en ligne est décrite dans la section 3.6.

3.2 Détection des phénomènes de dégradation

La dégradation est une évolution irréversible d'une ou plusieurs caractéristiques d'un composant, liée aux conditions d'utilisation ou à diverses causes externes [32, 101]. Le phénomène de dégradation peut être également défini par une perte progressive de performance d'une fonction d'un équipement, par exemple la perte de pression d'une pompe, comme illustré sur la figure 3.1.a ou une variation progressive d'un débit dû à une fuite, comme montré sur la figure 3.1.b .




FIGURE 3.1 – Variation de pression et de débit en sortie d'un réchauffeur.

Les phénomènes de dégradation peuvent être rapides ou lents (*cf* chapitre 1). Dans cette section, nous allons nous intéresser dans un premier temps aux techniques de détection de dérives rapides et dans un second temps aux techniques de détection de dérives lentes de fonctionnement.

3.2.1 Méthode de détection des dérives rapides

Dans ce manuscrit, une dérive rapide est caractérisée par un glissement rapide des observations dans l'espace de représentation, comme illustrée à la figure 3.2.

Une technique de régression sur les observations peut être utilisée pour modéliser la direction et la vitesse caractérisant la trajectoire des observations et aussi pour détecter des dérives rapides requises.




FIGURE 3.2 – Dérives rapides.

[9]. L'analyse de la trajectoire des observations permet de donner de l'information sur la tendance générale d'évolution des observations.

Soit $x_{k,v}$, la $v^{\text{ème}}$ composante du vecteur d'observation X_k à l'instant k . Une technique de régression linéaire pour chaque composante $x_{k,v}$ sur une fenêtre de données de taille Γ est proposée, en utilisant une fonction linéaire définie par la relation suivante :

$$f_v(k) = a_{k,v} k + b_{k,v}, \text{ avec } k \text{ instant courant} \quad (3.1)$$

$$V_k = [a_{k,1} \cdots a_{k,D}]^T. \quad (3.2)$$

avec les coefficients $a_{k,v}$ et $b_{k,v}$ estimés à chaque instant en minimisant le critère suivant.

$$e_{k,v} = \sum_{i_1=k-\Gamma+1}^k (x_{i_1,v} - f_v(i_1))^2. \quad (3.3)$$

$e_{k,v}$ représente l'écart entre la valeur réelle de $x_{k,v}$ et la valeur de $x_{k,v}$ estimée par la fonction linéaire f_v définie par la relation (3.1).

La taille Γ de la fenêtre glissante est choisie de manière à avoir une sensibilité minimale au bruit tout en respectant la qualité de la technique de régression choisie pour estimer la vitesse [9]. Une grande valeur de Γ peut entraîner un retard de détection.

Le vecteur de direction V_k donné par la relation (3.2) permet de modéliser la direction d'évolution des observations. Ce vecteur contient une estimation des vitesses d'évolution de chaque composante de X_k (voir figure 3.3). Le coefficient $a_{k,v}$ de la relation (3.2) représente la vitesse d'évolution des Γ observations suivant la $v^{\text{ème}}$ composante. Les vecteurs V_k sont mémorisés dans une fenêtre glissante $\Psi_{i,\Gamma}$ de taille Γ donnée par :

$$\Psi_{i,\Gamma} = [V_{k-\Gamma+1} \cdots V_k],$$

avec i le numéro de la classe d'appartenance de la composante v ($a_{k,v}$).

Le critère de détection de dérives rapides d'observations basé sur la direction, consiste à estimer à chaque instant k l'angle α_k formé entre chaque vecteur V_k de $\Psi_{i,\Gamma}$ et son précédent V_{k-1}




FIGURE 3.3 – Vitesse d'évolution des observations.

(voir figure 3.4). Lorsqu'une dérive rapide apparaît, tous les $V_k \in \Psi_{i,\Gamma}$ s'orientent successivement dans le même sens que la dérive et l'angle entre les vecteurs consécutifs de $\Psi_{i,\Gamma}$, devient de plus en plus petit. Les critères de détection de dérives rapides (utilisant la technique de régression) sont donnés par :

- $\alpha_j > \alpha_d$ pour un $j \in [k - \Gamma + 1 \ k] \Rightarrow$ Suivi,
- $\alpha_j \leq \alpha_d$ pour tout $j \in [k - \Gamma + 1 \ k] \Rightarrow$ Détection de dérives rapides.

Le cosinus de l'angle α_{k-1} est donné par :

$$\cos(\alpha_{k-1}) = \frac{AB}{AV_{k-1}}. \quad (3.4)$$

L'angle α_k est déterminé avec le même principe que pour α_{k-1} .




FIGURE 3.4 – Technique de détection des dérives rapides d'observations.

Le système dont l'espace de représentation est illustré à la figure 3.5.a, est caractérisé par un mode de fonctionnement normal, noté C_1 . Les vecteurs vitesses de la classe normale contenus dans $\Psi_{i,11}$ sont représentés à la figure 3.5.b. Sur cette figure, les vecteurs V_j contenus dans $\Psi_{i,11}$ ne s'orientent pas dans le même sens, donc il n'y a pas de dérive rapide de la classe C_1 .

Lorsqu'une dérive rapide apparaît, les observations ne respectent plus la loi des modèles des classes d'origine. Elles suivent une nouvelle allure (direction, vitesse) imposée par la nature de la dérive, comme illustré sur la figure 3.6.b. Sur cette figure, tous les vecteurs de $\Psi_{i,11}$ s'orientent dans le même sens, il s'agit d'une dérive rapide des observations.




FIGURE 3.5 – Technique de détection des dérives rapides, (a) - Pas d'évolution des observations de la classe C_1 , (b) - allure de la trajectoire des vitesses, avec $\Gamma = 11$.




FIGURE 3.6 – Technique de détection des dérives rapides, (a) - évolution des observations de la classe C_1 , (b) - allure de la trajectoire des vitesses, avec $\Gamma = 11$.

3.2.2 Méthode de détection des dérives lentes

Dans ce manuscrit, une dérive lente est caractérisée par un éloignement progressif du mode de fonctionnement du système par rapport à son mode de fonctionnement normal. La technique de détection présentée précédemment n'est pas adaptée pour détecter des dérives lentes. En effet, il s'agit de dérives très difficiles à détecter [67]. Cette nouvelle technique est basée sur l'analyse des mouvements des classes obtenues dynamiquement et correspondant aux modes de fonctionnement du système. Ces évolutions peuvent être un éloignement et/ou un grossissement ou une rotation de la classe évolutive. L'analyse des mouvements des classes s'appuie sur les paramètres des classes (centre, matrice de covariance) estimés grâce au classifieur *AUDyC* dynamique présenté dans le chapitre 2.

L'avantage de cette méthode réside dans sa capacité de détecter l'évolution lente des classes

et de savoir vers quel mode le système est en train d'évoluer. La méthode de détection des dérives lentes que nous proposons dans ce paragraphe s'appuie sur le calcul des métriques mesurant la distance entre les différents modes du système. Ces derniers sont supposés caractériser par des distributions gaussiennes. Le principe consiste à calculer en continu, le taux de dérive $T_{i,j}$ de la classe C_i par rapport à la classe de défaillance C_{d_j} sur une fenêtre de largeur N_{fen} .

Le taux de dérive $T_{i,j}$ est utilisé pour détecter tout changement de comportement du système. Il est calculé en utilisant la distance de Kullback-Leibler entre les différents modes de fonctionnement du système. Le taux $T_{i,j}$ exprimé en pourcentage permet de calculer la distance parcourue par la classe évolutive C_i en direction de la panne C_{d_j} sur une fenêtre de taille N_{fen} . L'expression de $T_{i,j}$ est donnée par la relation suivante :

$$\begin{cases} T_{i,j} = \frac{1}{N_{fen} - 1} \sum_{l=1}^{N_{fen}} \text{signe}(\Delta_l), \\ \Delta_j = [E_{k-N_{fen}+1,j} \cdots E_{k,j}]^\top, \\ E_{k,j} = \frac{d_{kl}(C_i^k, C_{d_j}) - d_{kl}(C_i^{k-1}, C_{d_j})}{\max(d_{kl}(C_i^k, C_{d_j}), d_{kl}(C_i^{k-1}, C_{d_j}))}, \end{cases} \quad (3.5)$$

avec C_i^k la classe C_i à l'instant k , C_{d_j} classe de défaillance d_j et $d_{kl}(\cdot)$ la distance de Kullback-Leibler donnée par [49].

$$\begin{aligned} d_{kl}(C_i^k, C_{d_j}) &= \frac{1}{2}(M_k - M_{d_j})^\top (\Sigma_k^{-1} + \Sigma_{d_j}^{-1})(M_k - M_{d_j}) \\ &\quad + \frac{1}{2} \text{tr}(\Sigma_k^{-1} \Sigma_{d_j} + \Sigma_k \Sigma_{d_j}^{-1}) - D, \end{aligned} \quad (3.6)$$

avec D la dimension de l'espace de représentation.

Lorsque la classe C_i évolue en direction de la classe de défaillance C_{d_j} , la grandeur $d_{kl}(C_i^k, C_{d_j}) - d_{kl}(C_i^{k-1}, C_{d_j})$ est négative. Cette grandeur est positive lorsque la classe C_i s'éloigne de la classe de défaillance C_{d_j} . Les critères de détection de dérives lentes d'un système sont présentés dans le tableau suivant :

Taux de dérive	État du système
$T_{i,j} \rightarrow -1$	La classe courante C_i^k dérive vers la classe de défaillance C_{d_j}
$T_{i,j} \approx 0$	La classe courante C_i^k ne dérive pas par rapport à la classe de défaillance C_{d_j}
$T_{i,j} \rightarrow 1$	La classe courante C_i^k s'éloigne de la classe de défaillance C_{d_j}

TABLE 3.1 – Détection des dérives lentes des modes de fonctionnement.

Jusqu'ici, nous nous sommes principalement intéressés à la définition et à la proposition d'outils de détection de phénomènes de dégradation. Nous allons maintenant nous pencher sur la proposition d'indicateurs de dégradation qui caractérisent l'état de dégradation et non plus simplement sa présence. Ces indicateurs vont être exploités par le processus de pronostic afin de prédire l'état futur du système ou de ses composants en temps réel.

3.3 Indicateurs de dégradation

Ayant défini dans le chapitre 2, l'algorithme *AUDyC* comme outil de modélisation, des indicateurs de dégradation construits à partir des règles de décision exploitant des degrés d'appartenance peuvent être envisagés. Cette technique est basée sur la représentation des modes de fonctionnement sous forme de partition dans un espace de décision.

Nous rappelons qu'à chaque nouvelle observation X_k présentée à l'entrée du réseau *AUDyC*, ses degrés d'appartenance aux différents modes connus sont évalués. De plus, l'appartenance de X_k à l'une des classes connues est définie à partir des degrés d'appartenance aux différents prototypes. Les nouvelles observations peuvent évoluer rapidement vers un autre mode ou successivement à l'intérieur d'une classe provoquant l'évolution de celle-ci. Les indicateurs de dégradation basés sur les degrés d'appartenance sont présentés par la suite.

3.3.1 Indicateurs de dégradation basés sur les fonctions d'appartenance

Les classes qui correspondent aux modes de fonctionnement contiennent des informations qui caractérisent les états normaux et anormaux des composants du procédé. A partir de la connaissance de la classe normale et anormale de chaque composant du procédé, la fonction d'appartenance des nouvelles observations à ces classes peut être utilisée comme un indicateur de dégradation. La fonction d'appartenance d'une nouvelle observation X_k à la classe C_i est donnée par :

$$\mu(X_k, C_i) = \exp(-\lambda_i d(X_k, C_i)^2), \quad (3.7)$$

où λ_i est une constante utilisée pour ajuster la "raideur" de la courbe exponentielle.

L'*AUDyC* utilise une fonction d'appartenance avec la distance de Mahalanobis. La distance de Mahalanobis est donnée par la relation (2.10) (*cf* chapitre 1) .

Comme introduit dans le paragraphe 3.2.1, les dérives rapides sont caractérisées par des glissements d'observations dans l'espace de représentation . La figure 3.7.a illustre des dérives rapides d'observations de la classe normale, noté C_{n_i} , en direction de la classe C_{d_j} et la figure 3.7.b représente les fonctions d'appartenance des nouvelles observations X_k à la classe C_{n_i} et à la classe C_{d_j} .

Les indicateurs de dégradation basés sur la fonction d'appartenance peuvent être définis par la relation suivante :

$$I_{d, C_{n_i}} = \mu(X_k, C_{n_i}) \quad \text{où} \quad I_{d, C_{d_j}} = \mu(X_k, C_{d_j}), \quad (3.8)$$

avec $I_{d, C_{n_i}}$ l'indicateur de dégradation associé à la classe normale i .

Lorsque les observations X_k s'éloignent d'un mode de fonctionnement, on voit leur fonction d'appartenance à ce mode décroître. Dans le cas contraire, on voit la fonction d'appartenance à ce mode accroître (*voir* figure 3.7.b).

Dans le cas d'un espace de décision dynamique et lorsque la dégradation est très progressive, les classes associées aux modes de fonctionnement normaux peuvent évoluer dans l'espace de




FIGURE 3.7 – Fonctions d’appartenance associée aux dérives rapides, (a) - dérives rapides des observations, (b) - évolution des fonctions d’appartenance.

représentation et suivre le mouvement des observations. L’évolution des classes C_{n_i} , comme illustré sur la figure 3.8 est due à l’évolution d’observations successives à l’intérieur des classes C_{n_i} . Dans ce cas, le degré d’appartenance de ces observations à la classe évolutive est sensiblement égal à 1, car X_k est associée à C_{n_i} . Dans cet espace de décision la fonction d’appartenance des nouvelles observations à la classe C_{e_i} est voisine de 1, or la classe C_{e_i} évolue en direction de la classe C_{d_j} . Cela rend inefficace un indicateur de dérive basé sur les fonctions d’appartenance.

Afin de remédier à ce problème, nous proposons une technique d’estimation des indicateurs de dégradation basée sur le pourcentage de la distance effectuée par la classe évolutive, c’est-à-dire le mode de fonctionnement dégradé, en direction de la classe de défaillance à chaque instant k .




FIGURE 3.8 – Dérives lentes des classes.

3.3.2 Indicateurs de dégradation basés sur les distances entre les modes

L’indicateur de dégradation du composant i , notée $I_{d,i}$, est basé sur le pourcentage de la distance effectuée par la classe évolutive C_{e_i} (mode dégradé) en direction de la classe de défaillance C_{d_j} . La mise de œuvre de cette technique nécessite une connaissance *a priori* des modes de fonctionnement normaux et anormaux de chaque composant du procédé. Le pourcentage de la distance effectuée par le mode dégradé en direction du mode anormal en temps réel est donné par :

$$\alpha^i(k) = \frac{d(C_{e_i}, C_{d_j})}{d(C_{n_i}, C_{d_j})}, \quad (3.9)$$

où $d(\cdot)$ désigne une distance et C_{n_i} , C_{e_i} et C_{d_j} représentent respectivement la classe normale, la classe évolutive et la classe défaillance du composant i .

La valeur $\alpha^i(k)$ est le pourcentage de la distance parcourue par la classe C_{e_i} en direction de la classe C_{d_j} à chaque instant k . La distance entre la classe normale C_{n_i} et la classe de défaillance C_{d_j} est utilisée pour normaliser l'expression de $\alpha^i(k)$.

Pour déterminer la valeur $\alpha^i(k)$ en temps réel, deux approches ont été proposées [72]. Une première approche est basée sur la distance Euclidienne (d_{eu}) et une seconde approche est basée sur la distance de Kullback-Leibler (d_{kl}). La mise en œuvre de ces deux approches est basée sur l'hypothèse suivante : chaque composant i du procédé ne peut être caractérisé que par deux modes de fonctionnement connus *a priori* : modes de fonctionnement normal C_{n_i} et anormal C_{d_j} . Le passage de la classe C_{n_i} à la classe C_{d_j} peut être réalisé de deux manières : passage abrupt (saut) ou passage progressif, c'est-à-dire l'apparition d'une classe évolutive C_{e_i} ou d'observations glissantes entre les deux modes de fonctionnement. Les deux approches d'estimation de $\alpha^i(k)$ sont présentées dans les paragraphes suivants.

3.3.2.1 Approche basée sur la distance Euclidienne

La distance Euclidienne entre les classes C_{n_i} , C_{e_i} et C_{d_j} du composant i est utilisée afin d'estimer à chaque instant k le pourcentage de la distance effectuée par la classe évolutive C_{e_i} en direction de la classe de défaillance C_{d_j} . L'expression de cette distance Euclidienne entre la classe C_{e_i} et la classe C_{d_j} est donnée par :

$$d_{eu}(M_{e_i}, M_{d_j})^2 = (M_{e_i} - M_{d_j})(M_{e_i} - M_{d_j})^\top, \quad (3.10)$$

avec M_{e_i} et M_{d_j} représentant respectivement le centre de la classe évolutive et de la classe de défaillance du composant i . La distance Euclidienne entre les modes normaux et défailants, notée $d_{eu}(M_{n_i}, M_{d_j})$ est définie de la même manière que la relation (3.10). Dans le cas d'une classe de forme complexe, la relation (3.10) est utilisée en fusionnant les prototypes modélisant la classe.

La valeur $\alpha_{eu}^i(k)$ du composant i déterminée en fonction de la distance Euclidienne est donnée par la relation suivante.

$$\alpha_{eu}^i(k) = \frac{d_{eu}(M_{e_i}, M_{d_j})}{d_{eu}(M_{n_i}, M_{d_j})}, \quad (3.11)$$

La valeur de $\alpha_{eu}^i(k)$ permet d'exprimer en pourcentage à chaque instant k la distance parcourue par la classe évolutive C_{e_i} en direction de la classe de défaillance C_{d_j} . Un exemple d'un composant soumis à des dérives lentes est illustré sur la figure 3.9. Les composantes du vecteur d'observation X_k sont x_1 et x_2 .

Pour simplifier la présentation de l'approche basée sur la distance Euclidienne, nous considérons uniquement l'évolution lente d'un mode de fonctionnement d'un seul composant i modélisé par une seule classe et un seul prototype (voir figure 3.10).

La distance $d_{eu}(M_{e_i}, M_{d_j}) = \mathbf{\Lambda}_i(k)$ de la figure 3.10 est déterminée à partir du triangle formé par les centres des différentes classes C_{n_i} , C_{e_i} et C_{d_j} du composant i . La distance $\mathbf{\Lambda}_i(k)$ est




FIGURE 3.9 – Illustration des dérives lentes des modes d'un fonctionnement, avec C_{n_i} , C_{e_i} et C_{d_i} respectivement la classe normale, la classe évolutive et la classe de défaillance du composant i .

calculée à chaque instant k en fonction des distances $\mathbf{Y}_i = \left\| \overrightarrow{M_{n_i} M_{e_i}} \right\|$ et $\mathbf{Z}_i = \left\| \overrightarrow{M_{d_j} M_{e_i}} \right\|$. Les distances \mathbf{Y}_i et \mathbf{Z}_i sont calculées selon l'expression suivante :

$$\begin{cases} \mathbf{Y}_i(k)^2 = (M_{n_i} - M_{e_i})(M_{n_i} - M_{e_i})^\top, \\ \mathbf{Z}_i(k)^2 = (M_{d_j} - M_{e_i})(M_{d_j} - M_{e_i})^\top \\ d_{eu}(M_{n_i}, M_{d_j})^2 = (M_{n_i} - M_{d_j})(M_{n_i} - M_{d_j})^\top. \end{cases} \quad (3.12)$$




FIGURE 3.10 – Dérives lentes, (a) - dérive lente du mode de fonctionnement d'un composant, (b) - l'indicateur de dérive $I_{d,i}$ du composant.

Les caractéristiques de la classe évolutive (M_{e_i} , Σ_{e_i}) sont mises à jour à chaque instant k par la relation (2.46) ou (2.47) (l'algorithme *AUDyC*). La classe C_{e_i} évolue en direction de la classe C_{d_j} si et seulement si l'angle $\beta = \widehat{M_{e_i} M_{n_i} M_{d_j}}$ de la figure 3.10.a est compris entre $-\frac{\pi}{2}$ et $\frac{\pi}{2}$ et le taux de dérive défini par la relation (3.5) tend vers -1 . Dans le cas contraire, le mode

de fonctionnement dégradé du composant i évolue vers un mode de fonctionnement inconnu. Compte tenu d'une dérive lente de C_{n_i} vers le mode C_{d_j} à l'instant k , nous définissons la valeur $1 - \alpha_{eu}^i(k)$ comme un indicateur de dégradation du composant i , notée $I_{d,i}(k)$. Cette indicateur permet de suivre en temps réel, l'état de dégradation de chaque composant i du procédé. Le composant i est déclaré défaillant si et seulement $I_{d,i}(k) = 1$. L'expression de l'indicateur de dégradation est donnée par la relation suivante :

$$\begin{cases} I_{d,i}(k) = 1 - \alpha_{eu}^i(k), \\ \alpha_{eu}^i(k) = \frac{\Lambda_i(k)}{d_{eu}(M_{n_i}, M_{d_j})} \text{ avec } \Lambda_i(k) = \frac{1}{2} \left[d_{eu}(M_{n_i}, M_{d_j}) - \frac{\mathbf{Y}_i(k)^2 - \mathbf{Z}_i(k)^2}{d_{eu}(M_{n_i}, M_{d_j})} \right]. \end{cases} \quad (3.13)$$

L'approche d'estimation des indicateurs de dégradation $I_{d,i}$ basée sur la distance Euclidienne a deux avantages : elle est facile à interpréter et à mettre en œuvre. Mais, cette approche ne prend pas en compte de la géométrie (forme, orientation) des classes évolutives. En effet, il est intéressant de prendre en compte la variance des modes de fonctionnement dans le calcul des indicateurs de dégradation. Cependant afin de prendre en compte la variance des modes de fonctionnement, nous proposons d'utiliser la distance de Kullback-Leibler qui permet de calculer la distance entre deux distributions.

3.3.2.2 Approche basée sur la distance de Kullback-Leibler

La distance de Kullback-Leibler (d_{kl}) entre deux distributions continues $p_1(x)$ et $p_2(x)$ est la quantité définie selon la relation suivante [49, 36].

$$d_{kl}(p_1(x), p_2(x)) = \int p_1(x) \log \frac{p_1(x)}{p_2(x)} dx. \quad (3.14)$$

Avec l'hypothèse de modèles gaussiens pour les classes, la relation (3.14) est remplacée par la relation (3.15) [11, 72].

$$d_{kl}(C_1, C_2) = \frac{1}{2}(M_1 - M_2)^\top (\Sigma_1^{-1} - \Sigma_2^{-1})(M_1 - M_2) + \frac{1}{2} \text{tr}(\Sigma_1^{-1}\Sigma_2 + \Sigma_1\Sigma_2^{-1}) - D, \quad (3.15)$$

où D est la dimension de l'espace de représentation.

En effet, chaque classe C_i est caractérisée par un centre M_i et une matrice de covariance Σ_i (*cf* chapitre 2).

La distance de Kullback-Leibler définie par la relation (3.15) est utilisée pour déterminer en pourcentage, la distance effectuée par la classe évolutive C_{e_i} en direction de la classe de défaillance C_{d_j} . Le pourcentage α_{kl}^i de la distance effectuée par la classe C_{e_i} en direction de la classe C_{d_j} est donné par :

$$\alpha_{kl}^i(k) = \frac{d_{kl}(C_{e_i}, C_{d_j})}{d_{kl}(C_{n_i}, C_{d_j})}. \quad (3.16)$$

L'indicateur $I_{d,i}(k)$ basé sur la distance de Kullback-Leibler est donnée par :

$$I_{d,i}(k) = 1 - \alpha_{kl}^i(k). \quad (3.17)$$

Pour que l'indicateur $I_{d,i}$ soit compris entre 0 et 1, nous utilisons l'hypothèse basée sur le taux de dérive $T_{i,j}$ défini par la relation (3.5). Le mode de fonctionnement dégradé du composant i évolue en direction du mode défaillant C_{d_j} si et seulement si le taux $T_{i,j} \rightarrow -1$. L'avantage de cette approche réside dans sa capacité à prendre en compte les différents changements que peut subir une classe évolutive, comme illustré sur la figure 3.11.




FIGURE 3.11 – Différents types de changements possibles pour une classe évolutive.

Afin d'interpréter la pertinence des indicateurs $I_{d,i}$ en fonction du type de distance utilisée, nous considérons le scénario illustré sur la figure 3.12. Le scénario est constitué d'une classe normale $C_{n_i} (M_{n_i}, \Sigma_{n_i})$ et d'une classe de défaillance $C_{d_j} (M_{d_j}, \Sigma_{d_j})$ connues *a priori*, ainsi que d'une classe évolutive $C_{e_i} (M_{e_i}^l, \Sigma_{e_i}^l)_{l=1, \dots, 3}$. La classe C_{e_i} peut avoir plusieurs formes et positions comme illustré sur la figure 3.12. Les classes $C_{e_i}^1$ et $C_{e_i}^2$ ont le même centre, cependant leurs matrices de covariances sont différentes. La classe $C_{e_i}^3$ est caractérisée par un autre centre et une autre matrice de covariance. Les caractéristiques des modes représentés sur la figure 3.12 sont :

$$M_{n_i} = \begin{bmatrix} 10 \\ 5 \end{bmatrix} \quad M_{d_j} = \begin{bmatrix} 50 \\ 5 \end{bmatrix} \quad M_{e_i}^1 = \begin{bmatrix} 30 \\ 15.5 \end{bmatrix} \quad M_{e_i}^2 = \begin{bmatrix} 30 \\ 15.5 \end{bmatrix} \quad M_{e_i}^3 = \begin{bmatrix} 33 \\ 10 \end{bmatrix}. \quad (3.18)$$

$$\Sigma_{n_i} = \begin{bmatrix} 4 & 0 \\ 0 & 4 \end{bmatrix} \quad \Sigma_{d_j} = \begin{bmatrix} 4 & 0 \\ 0 & 4 \end{bmatrix} \quad \Sigma_{e_i}^1 = \begin{bmatrix} 3 & 0 \\ 0 & 3 \end{bmatrix} \quad \Sigma_{e_i}^2 = \begin{bmatrix} 11 & 4 \\ 0 & 6 \end{bmatrix} \quad \Sigma_{e_i}^3 = \begin{bmatrix} 2.902 & 1 \\ 0 & 3 \end{bmatrix}. \quad (3.19)$$




FIGURE 3.12 – Classe évolutive C_{e_i} avec différentes formes, positions et orientations.

Sur l'exemple de la figure 3.12, nous appliquons les deux techniques présentées précédemment pour estimation des indicateurs de dégradation $I_{d,i}$ à chaque instant k . La valeur de $I_{d,i}$ est estimée en fonction des différentes formes, directions et orientations que peut prendre la classe

évolutive $(C_{e_i}^l)_{l=1,\dots,3}$. Les valeurs de $I_{d,i}$ associées à chaque classe $C_{e_i}^l$ sont présentées sur le tableau 3.2. Ces indicateurs sont estimés par la technique basée sur la distance Euclidienne et la technique basée sur la distance de Kullback-Leibler.

Basée sur la distance :	Indicateurs	$C_{e_i}^1 \mapsto C_{d_j}$	$C_{e_i}^2 \mapsto C_{d_j}$	$C_{e_i}^3 \mapsto C_{d_j}$
Euclidienne	$I_{d,i} = 1 - \alpha_{eu}^i$	0.50	0.50	0.57
Kullback-Leibler	$I_{d,i} = 1 - \alpha_{kl}^i$	0.39	0.5046	0.5046

TABLE 3.2 – Indicateurs de dégradation calculés par les deux approches.

► Interprétation des indicateurs de dégradation estimés selon la distance Euclidienne ou la distance de Kullback-Leibler

L'approche basée sur la distance Euclidienne montre que les indicateurs de dégradation associés aux classes $C_{e_i}^1$ et $C_{e_i}^2$ sont identiques malgré leur différence de formes. L'indicateur associé à la classe $C_{e_i}^3$ est plus important que les deux autres. Cela signifie que la classe $C_{e_i}^3$ est plus proche de la classe de défaillance C_{d_j} et que les classes $C_{e_i}^1$ et $C_{e_i}^2$ sont à égale distance de la classe C_{d_j} . La technique d'estimation de l'indicateur de dégradation basée sur la distance Euclidienne est facile à interpréter et à mettre en œuvre. Cependant, elle ne prend pas en compte la forme et l'orientation de la classe évolutive.

La technique basée sur la distance de Kullback-Leibler montre que l'indicateur $I_{d,i}$ associé à la classe $C_{e_i}^2$ est différent de l'indicateur associé à la classe $C_{e_i}^1$. Bien que la matrice de covariance de la classe $C_{e_i}^1$ soit inférieure à la matrice de covariance de la classe $C_{e_i}^2$, la différence entre les indicateurs semble trop importante. Par ailleurs, les indicateurs associés à la classe $C_{e_i}^2$ et $C_{e_i}^3$ sont identiques, même si la classe $C_{e_i}^3$ est plus proche de la classe de défaillance C_{d_j} (voir figure 3.12). La technique basée sur la distance Kullback-Leibler permet de prendre en compte la forme et l'orientation des classes, mais les indicateurs fournis par cette approche ne sont pas toujours interprétables comme une évolution non réversible d'un composant [72]. Les indicateurs basés sur la distance de Kullback-Leibler se confrontent également à la difficulté d'estimer correctement la variance d'un mode de défaillance C_{d_j} .

Afin de fournir des indicateurs pertinents qui prennent en compte la forme, l'orientation et la position des classes correspondant aux modes de fonctionnement des composants du procédé, nous proposons une nouvelle technique d'estimation de $I_{d,i}$ en continu. Cette technique est basée sur la combinaison pondérée de la distance Euclidienne et du deuxième terme de la distance de Kullback-Leibler (3.15). Car le deuxième terme de la distance de Kullback-Leibler permet de prendre en compte la forme et l'orientation des classes.

3.3.3 Autre technique d'estimation de $I_{d,i}$

La nouvelle approche d'estimation de $I_{d,i}$ que nous proposons est basée sur le couplage de la distance euclidienne et le deuxième terme de la distance Kullback-Leibler. Elle permet de prendre en compte la forme, l'orientation et l'évolution des classes. Cette nouvelle approche est

applicable aux dérivés lentes et rapides des modes de fonctionnement. L'expression de la nouvelle approche, basé sur l'équation 3.13 est donnée par :

$$\left\{ \begin{array}{l} I_{d,i}(k) = 1 - \left(\frac{\Lambda_i(k)}{d_{eu}(M_{n_i}, M_{d_j}) + \tau_i(k)} \right) \\ \tau_i(k) = \lambda \delta_i(k) \text{ avec } \left\{ \begin{array}{l} \delta_i(k) = \frac{\psi_i(k)}{\psi_i(k) + \nu_i}, \\ \psi_i(k) = \text{tr}(\Sigma_{e_i} \Sigma_{d_j}^{-1} + \Sigma_{e_i}^{-1} \Sigma_{d_j}), \\ \nu_i = \text{tr}(\Sigma_{d_j} \Sigma_{n_i}^{-1} + \Sigma_{d_j}^{-1} \Sigma_{n_i}), \end{array} \right. \end{array} \right. \quad (3.20)$$

où λ est un coefficient de pondération qui est compris entre 0 et 1, et $\Lambda_i(k)$ est défini selon la relation 3.13. L'influence de la géométrie de la classes C_{e_i} dans l'expression 3.20 est pris en compte grâce au paramètre τ_i . Par exemple, l'élargissement de la classe C_{e_i} aura pour effet d'augmenter l'indicateur $I_{d,i}$.

Le choix de λ a une forte influence sur le calcul de l'indicateur de dégradation $I_{d,i}$. Tandis que si la valeur de λ est trop petite, la forme et l'orientation de la classe courante ne sont pas prises en compte, ce qui conduit à ne considérer que l'approche basée sur la distance Euclidienne. Si la valeur de λ est trop grande, la forme et l'orientation de la classe courante ont trop d'influence sur l'estimation de l'indicateur $I_{d,i}$ ce qui nous ramène aux limites citées dans le paragraphe 3.3.2.2. Il est donc important de faire un compromis pour effectuer un bon choix de la valeur de λ . La grandeur $\delta_i(k)$ de la relation (3.20) permet de prendre en compte le grossissement et la rotation de la classe courante (classe évolutive). L'erreur sur l'estimation de la matrice de variance de la classe de défaillance est réduit par la valeur de λ .

Dans le tableau 3.3, nous présentons les indicateurs de dégradation associées aux classes $C_{e_i}^1$, $C_{e_i}^2$ et $C_{e_i}^3$ en utilisant la nouvelle expression d'estimation de $I_{d,i}$ définie par la relation (3.20). Nous constatons que la classe $C_{e_i}^3$ est plus proche de la classe de défaillance C_{d_j} , que la classe $C_{e_i}^2$ et cette dernière est plus proche de la classe de défaillance que la classe $C_{e_i}^1$.

Indicateurs	$C_{e_i}^1 \mapsto C_{d_j}$	$C_{e_i}^2 \mapsto C_{d_j}$	$C_{e_i}^3 \mapsto C_{d_j}$
$I_{d,i} = 1 - \left(\frac{\Lambda_i(k)}{d_{eu}(M_{n_i}, M_{d_j}) + 0.8 \delta_i(k)} \right)$	0.5051	0.5056	0.5793

TABLE 3.3 – Indicateurs de dégradation estimés par la nouvelle approche.

La nouvelle approche d'estimation de $I_{d,i}$ donnée par la relation (3.20) permet d'obtenir des indicateurs pertinents sur la dégradation des composants du système évolutif.

Nous illustrons sur la figure 3.13.a un exemple de dérivés lentes d'un mode normal du composant i en direction d'un mode de fonctionnement défaillant de ce même composant. Ainsi, l'indicateur $I_{d,i}$ est représenté à la figure 3.13.b en utilisant l'approche basée sur la distance Euclidienne et la nouvelle approche que nous avons proposé. Nous constatons que cet indicateur a permis de prendre en compte la géométrie de la classe illustrée sur la figure 3.13.a.

Les indicateurs de dégradation $I_{i,d}$ estimés en temps réel sont exploités par le processus de pronostic de défaillance afin de prédire l'état futur du système ou de ses composants. Le pronostic

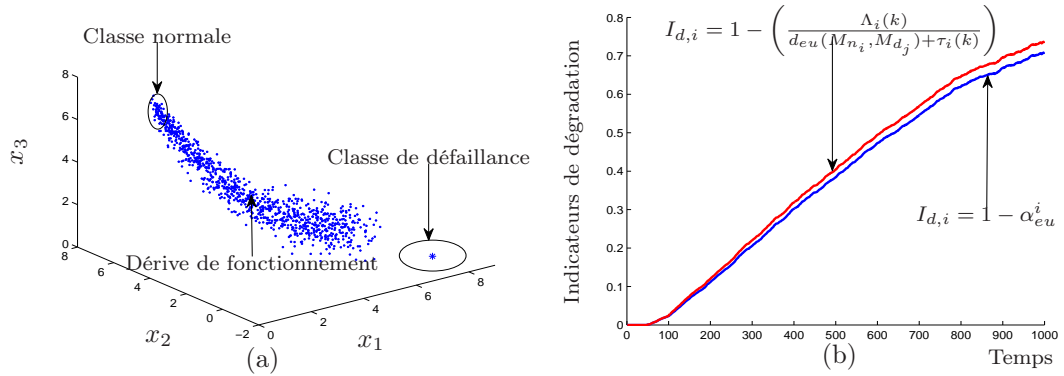


FIGURE 3.13 – Indicateurs de dégradation, (a) - dérives lentes de la classe normale et (b) - $I_{d,i}$ estimés par les trois approches, $\lambda = 0.9$.

de défaillance que nous proposons dans cette thèse a pour rôle d'estimer la probabilité qu'une défaillance d'un système ou de ses composants survienne à un instant futur donné.

Pour obtenir une approche de pronostic de défaillance efficiente pour de systèmes dynamiques évolutifs, nous proposons de combiner la méthode de pronostic guidée par les données avec les méthodes d'analyse de défaillances. Les méthodes d'analyse de défaillances les plus couramment utilisées sont présentées dans la section suivante.

3.4 Méthodes d'analyse de défaillances

3.4.1 Description de la démarche

La démarche proposée pour la mise en œuvre du pronostic de défaillance de systèmes dynamiques évolutifs (*SDE*), repose d'une part sur une modélisation précise des connaissances expertes préexistantes (*AMDE*, Arbre de défaillance (*AdD*)) et d'autre part sur des outils de supervision adaptative permettant de déterminer en temps réel les probabilités d'occurrence des événements élémentaires de l'arbre de défaillance. Nous supposons que chaque composant du système est caractérisé par trois modes de fonctionnement : mode normal, mode dégradé et mode anormal.

L'*AMDE* est une méthode de la sûreté de fonctionnement, qui est très répandue dans le milieu industriel. Son objectif est de permettre une analyse systématique, composant par composant, de tous les modes de défaillance possibles. Elle permet de déterminer les types de dérives possibles, et de préciser les effets de la défaillance sur le système. La démarche *AMDE* consiste à étudier un seul mode de défaillance à la fois, en faisant l'hypothèse que tout le reste du système fonctionne correctement. Pour prendre en compte les effets d'une combinaison de défaillances au lieu d'étudier les effets d'un seul mode de défaillance, la technique de l'arbre de défaillance peut être utilisée. Le point de départ de cette technique reste basé sur l'analyse *AMDE* du procédé.

La technique de l'*AdD* permet de représenter l'ensemble des combinaisons de défaillances possibles aboutissant à l'indisponibilité du procédé, c'est-à-dire l'occurrence de l'événement in-

désirable. L'*AdD* est un outil majeur d'analyse de risque technologique qui a l'avantage d'être simple à mettre en œuvre et facilement compréhensible.

Notre objectif est de déterminer à chaque instant k les probabilités de chacun des événements élémentaires de l'arbre de défaillance (voir figure 3.14). Les événements élémentaires sont des événements correspondant au niveau le plus détaillé de l'analyse du système. Dans un arbre de défaillance, ils représentent les défaillances des composants qui constituent le système étudié. Les probabilités des événements intermédiaires et de l'événement indésirable sont obtenues par la propagation des événements élémentaires en utilisant des relations "cause à effet" entre les différents événements. Les techniques de propagation des événements élémentaires sont présentées dans le paragraphe suivant.

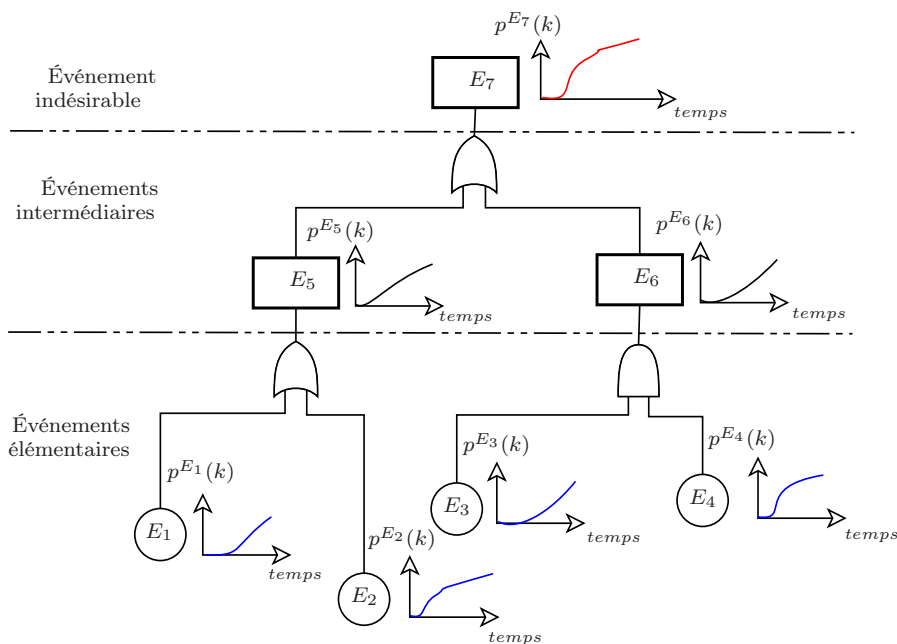


FIGURE 3.14 – Exemple d'un *AdD* d'un système, dont les composants sont sujets à des défaillances progressives.

3.4.2 Propagation des probabilités d'occurrence des événements

Les probabilités des événements intermédiaires et de l'événement indésirable de l'*AdD* sont obtenues par la propagation des probabilités des événements élémentaires de l'arbre. Cette propagation est faite en tenant compte des relations causes/effets des différents événements, c'est-à-dire des portes logiques *OU* et/ou *ET*.

- La probabilité en aval d'une porte *ET* est obtenue par le produit des probabilités correspondant aux événements en amont de la porte, définie par :

$$\mathbb{P}\left(\bigcap_{i=1}^n E_i\right) = \prod_{i=1}^n \mathbb{P}(E_i) = \mathbb{P}(E_1) \times \dots \times \mathbb{P}(E_n). \quad (3.21)$$

Les événements élémentaires de l'arbre sont supposés indépendants.

- La probabilité en aval d'une porte OU est obtenue en appliquant la formule de Poincaré sur les probabilités correspondant aux événements en amont de la porte. La formule de Poincaré est définie par l'expression suivante :

$$\mathbb{P}\left(\bigcup_{i=1}^n E_i\right) = \sum_{i=1}^n \left[(-1)^{i-1} \sum_{1 \leq i_1 < \dots < i_i \leq n} \mathbb{P}(E_{j_1} \cap \dots \cap E_{j_i}) \right], \quad (3.22)$$

avec n le nombre d'événements en amont de la porte OU .

Les probabilités d'occurrence de défaillance estimées en temps réel permettent d'évaluer les risques en calculant la criticité⁷ de chaque événement (Criticité = probabilité × gravité).

3.4.3 Estimation de probabilités en temps réel

Pour obtenir des probabilités d'occurrence des événements de l'arbre de défaillance évoluant au cours du temps, deux approches sont proposées par la suite. La première approche est proposée dans [33]. Cette approche est basée sur le calcul de la probabilité par intervalle de temps. La deuxième approche que nous proposons est basée sur le suivi en continu des indicateurs de dégradation de l'état de fonctionnement des composants. Les deux approches de calcul des probabilités d'occurrences de défaillance sont présentées dans les paragraphes suivants.

3.4.3.1 Estimation de probabilité par intervalle de temps

M. Desinde [33] a proposé à partir des résultats de l'*AMDEC* et du *GCD* (Graphe Causal de Dysfonctionnement) une approche permettant de déterminer à chaque instant k , les probabilités de chaque mode du graphe. Un *GCD* est un *AdD* avec plusieurs événements indésirables. Les probabilités d'occurrence des modes du graphe sont définies par intervalles de temps. Elles sont mises à jour à chaque instant de diagnostic pour qu'il soit possible de déterminer les risques de défaillances susceptibles d'apparaître et les conséquences les plus probables liées à leurs occurrences et à leurs criticités. Le *GCD* est rendu dynamique en attribuant à chaque événement élémentaire de l'arbre une probabilité évoluant dans le temps. Pour ce faire, M. Desinde a introduit la notion de Fonction de Probabilité par Episode (*FPE*), qui est présentée par la suite. La *FPE_i* de chaque événement E_i de l'arbre est considérée comme un indicateur de détérioration du composant i .

3.4.3.2 Notion de Fonction de Probabilité par Episode

FPE_i est une fonction constante par morceaux qui définit la probabilité d'occurrence d'un mode du graphe pendant un intervalle de temps. La fonction *FPE_i* de l'événement E_i est donnée

7. Le risque est la prise en compte d'une exposition à un danger, un préjudice ou autre événement dommageable, inhérent à une situation ou une activité. Le risque est défini par la probabilité de survenue de cet événement et par l'ampleur de ses conséquences (aléa et enjeu).

par :

$$FPE_i = ((p_1, \Delta k_1), \dots, (p_n, \Delta k_n)), \quad (3.23)$$

tels que $\forall k \in \Delta k_j \quad p^{E_i}(k) = p_j$ avec $\Delta k_j = [k_j^- \quad k_j^+]$.

Graphiquement, FPE_i est une fonction par escalier, comme illustré sur la figure 3.15. Les fonctions FPE des composants du procédé sont généralement déterminées à partir du retour d'expérience ou de tests d'usine (usure, fatigue, etc.). Ensuite, les fonctions FPE_i des événements intermédiaires et de l'événement indésirable sont obtenues par la propagation des FPE des événements élémentaires. La capitalisation du retour d'expérience doit alors être assurée par le service de maintenance [33].




FIGURE 3.15 – Représentation graphique d'une FPE .

Dans cette approche, les difficultés résident d'une part dans la caractéristique statique des FPE des événements élémentaire, et d'autre part dans la difficulté liée à la réévaluation des probabilités et au temps d'attente nécessaire à l'obtention de données de retour d'expérience afin de construire les FPE des composants. Pour remédier à ces difficultés, nous utilisons notre système de supervision, capable de fournir en continu les indicateurs de dégradation lente d'un système ou de ses composants. La méthode d'estimation de probabilité d'occurrence de défaillance des SDE que nous proposons est basée sur l'exploitation des indicateurs de dégradation présentés par la relation 3.20.

3.4.3.3 Estimation de probabilités à partir de suivi des classes

Pour temporiser et probabiliser l'arbre de défaillance d'un SDE , nous considérons les indicateurs de dégradation définis par la relation 3.20 comme des probabilités d'occurrence d'une défaillance. En effet, nous nous situons dans un contexte de défaillances progressives du système ou de ses composants. La probabilité d'occurrence de défaillance de chaque événement E_i , notée $p^{E_i}(k) = I_{d,i}(k)$, à chaque instant k est donnée par :

$$p^{E_i}(k) = 1 - \left(\frac{\Lambda_i(k)}{d_{eu}(M_{n_i}, M_{d_j}) + \tau_i(k)} \right). \quad (3.24)$$

L'estimation de la probabilité p^{E_i} est basé sur le pourcentage de la distance effectuée par la classe évolutive C_{e_i} (mode dégradé) en direction de la classe de défaillance C_{d_j} . La probabilité $p^{E_i}(k)$ permet de déterminer en temps réel, l'état de dégradation du composant i du procédé.

Un composant i est déclaré défaillant si et seulement si $p^{E_i}(k) = 1$. Par la suite du manuscrit, la notion des fonctions FPE_i est remplacée par $p^{E_i}(k)$.

Nous nous appuyons par la suite sur les valeurs p^{E_i} pour prédire la probabilité qu'une défaillance du composant i (apparition de l'événement E_i) survienne sur un temps futur donné. La prédiction de chaque événement élémentaire de l'arbre est propagée sur l'arbre afin de pronostiquer l'état futur de l'événement indésirable du système, ainsi que sa criticité future. Dans le contexte général de la maintenance prévisionnelle, la valeur probabiliste du pronostic de défaillance est d'autant plus une indication intéressante que le défaut ou la défaillance peuvent avoir des conséquences catastrophiques [101]. Nous rappelons, la connaissance de la probabilité future de chaque composant du système en temps réel permet l'aide à la prise de décision et à la planification d'actions de maintenance prévisionnelle. La définition et les différentes approches de pronostic sont présentées dans la section suivante.

3.5 Pronostic de défaillance

Contrairement au diagnostic dont le rôle est de déterminer dans quel mode de fonctionnement le procédé évolue, le pronostic de défaillance a pour rôle de prédire l'état futur du procédé ou de ses composants après la détection d'une dégradation. Dans la littérature, il existe plusieurs approches de pronostic qui reposent sur différents modèles [87]. Ces approches de pronostic peuvent être classées en trois catégories [34, 20] : approches de pronostic basées sur un modèle physique, approches de pronostic guidées par les données et approches de pronostic basées sur les données de retour d'expérience.

L'inconvénient majeur des approches basées sur les modèles physiques est qu'il est difficile et coûteux d'obtenir le modèle mathématique de la dégradation d'un procédé industriel, d'autant plus que les phénomènes de dégradation sont aléatoires ou sont soumis à des facteurs influents dont il est impossible de tenir compte de manière exhaustive. De plus, les modèles mathématiques de dégradation où les lois de probabilité utilisées sont propres à chaque type de composant, matériau ou machine et ne peuvent être que difficilement généralisées. Les approches basées sur l'expérience sont moins précises et souffrent souvent du manque de données de retour d'expérience. Les données sont généralement incomplètes et le temps nécessaire à leur collection peut être très important.

La complexité et le comportement généralement évolutif des systèmes réels, la difficulté à obtenir un modèle de dégradation et le temps nécessaire pour disposer de données de retour d'expérience suffisamment informatives conduisent à la proposition d'approches de pronostic guidées par les données. Elles ont l'avantage de ne pas nécessiter la connaissance de modèles analytiques des dégradations.

Dans ce travail, les approches de pronostic guidées par les données sont basées sur l'exploitation des indicateurs de dégradation délivrés par le processus de supervision, notamment l'outil de modélisation, de détection et de diagnostic.

Les systèmes de supervision et de pronostic de défaillance sont complémentaires. Le premier

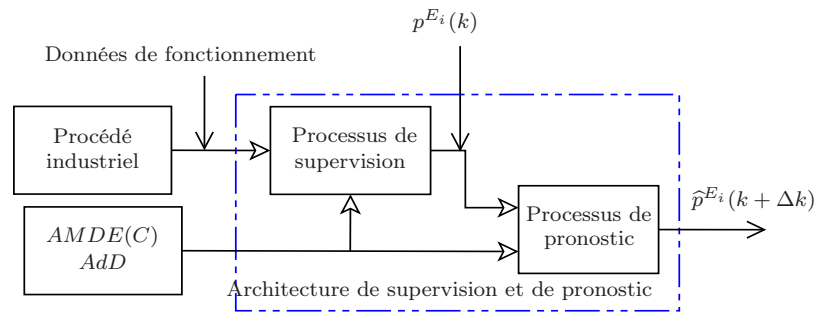


FIGURE 3.16 – Interaction entre les processus de supervision et de pronostic.

évalue l'état courant du système et transmet l'information au second qui effectue la projection de l'état du composant dans le futur, comme illustré sur la figure 3.16. Le processus de pronostic a pour entrée les probabilités $p^{E_i}(k)$ fournies par le processus de supervision et pour sortie la situation future du système sur un horizon de temps Δk . Le processus de supervision situé en amont conditionne le succès du processus de pronostic par sa capacité à fournir une estimation fiable et précise de l'état courant du procédé. Les approches de pronostic guidées par les données peuvent être divisées en deux grandes catégories : le pronostic par apprentissage automatique et le pronostic par analyse de tendance.

3.5.1 Pronostic par apprentissage automatique

Le pronostic par apprentissage automatique utilise les modèles d'apprentissage telles que les réseaux de neurones pour faire la prédiction sur le comportement du système. L'apprentissage va consister à ajuster les poids et les seuils des neurones afin d'obtenir la sortie prédite pour chaque paramètre du système. Le réseau de neurones est ensuite utilisé pour prédire l'évolution de la dégradation de ces paramètres dans des conditions opérationnelles (ou utilisation) similaires [88, 56, 87]. Le réseau de neurones peut être à ondelettes dynamiques [104], à fonctions de base radiale [108] ou neuro-flou [34, 101]. Les applications récentes de réseaux de neurones pour le pronostic s'orientent vers l'utilisation des réseaux de neurones adaptatifs, plus spécifiquement, du système neuro-flou *ANFIS* (Adaptive Neuro-Fuzzy Inference System). La méthode *ANFIS* a été introduite par C. Jang [94]. Elle est basée sur la technique d'apprentissage neuro-adaptative qui a l'avantage d'être un approximateur universel. *ANFIS* est une méthode de prédiction utilisée dans différentes applications de prédiction [8, 54]. Les paramètres des fonctions d'appartenance d'un modèle flou sont réglés en utilisant un algorithme de rétro-propagation combiné avec une méthode des moindres carrés.

3.5.1.1 Structure de la méthode *ANFIS*

La structure d'un réseau *ANFIS* met en application un système d'inférence flou du type Takagi-Sugeno-Kang (*TSK*). Elle est composée de cinq couches.

L'algorithme de rétro-propagation permet le réglage des paramètres prémisses. La méthode

des moindres carrés conduit à la détermination des paramètres conséquents.

Pour simplifier la présentation et sans perte de généralité, nous considérons un système à deux entrées x_1 et x_2 et à une sortie y , comme montré sur la figure 3.17.

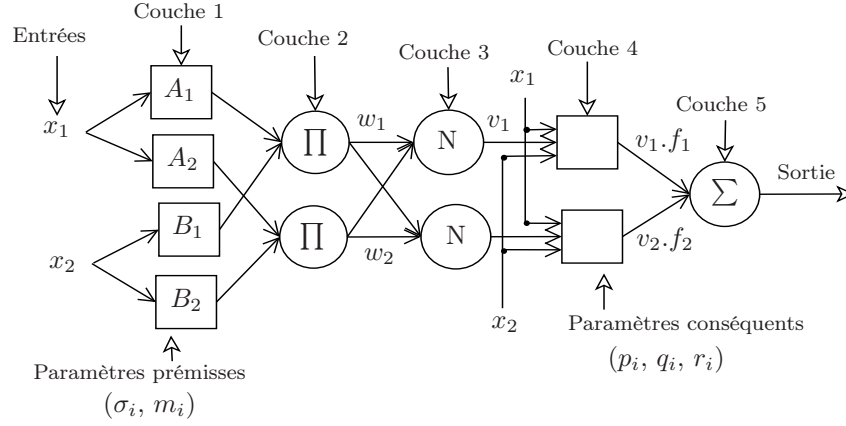


FIGURE 3.17 – Architecture d'ANFIS

Nous considérons également le modèle flou de type *TSK* de ce système en n'utilisant que deux règles. Les règles sont :

- Si x_1 est A_1 et x_2 est B_1 alors

$$y_1 = f_1(x_1, x_2) = p_1x_1 + q_1x_2 + r_1. \quad (3.25)$$

- Si x_1 est A_2 et x_2 est B_2 alors

$$y_2 = f_2(x_1, x_2) = p_2x_1 + q_2x_2 + r_2, \quad (3.26)$$

où p_i , q_i et r_i sont des paramètres conséquents.

Shing et Jang [94] ont proposé de représenter cette base de règles par le réseau adaptatif de la figure 3.17. Les nœuds du réseau *ANFIS* sont de deux types différents selon leur fonctionnalité : les nœuds carrés (adaptatifs), qui contiennent des paramètres et les nœuds circulaires (fixes), qui n'ont pas de paramètre. Toutefois, chaque nœud applique une fonction sur les signaux d'entrées. La sortie O_i^l du nœud i de la couche l , appelée nœud(i, l), dépend des signaux provenant de la couche $l - 1$ et des paramètres du nœud(i, l), c'est-à-dire.

$$O_i^l = f(O_1^{l-1} \dots O_{n_{l-1}}^{l-1}, p_l, q_l, r_l), \quad (3.27)$$

où n_{l-1} est le nombre de nœuds dans la couche $l - 1$, et p_l , q_l , r_l sont les paramètres conséquent du nœud(i, l). Pour un nœud circulaire, ces paramètres n'existent pas.

- **Couche 1** : Les neurones de cette couche réalisent les ensembles flous qui serviront dans les antécédents des règles. Dans le modèle de Shing et Jang, les fonctions d'appartenance sont des gaussiennes de centre m_i et d'écart type σ_i (classes floues).

$$O_i^1 = \begin{cases} \mu_{A_i}(x_1), & \text{pour } i = 1 \text{ et } 2, \\ \mu_{B_{i-2}}(x_2), & \text{pour } i = 3 \text{ et } 4, \end{cases} \quad (3.28)$$

où A_i et B_{i-2} sont des termes linguistiques.

En d'autres termes, O_i^1 est le degré d'appartenance de x_1 à A_i . Les paramètres d'un nœud de cette couche sont ceux de la fonction d'appartenance correspondante.

- **Couche 2** : Chaque neurone dans cette couche correspond à une règle floue de Takagi-Sugeno. Il reçoit les sorties des neurones de fuzzification et calcule leur activation. La conjonction des antécédents est réalisée avec l'opérateur produit.

$$O_i^2 = w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2), i = 1, 2. \quad (3.29)$$

- **Couche 3** : Chaque neurone calcule le degré de vérité normalisé d'une règle floue donnée. La valeur obtenue représente la contribution de la règle floue au résultat final.

$$O_i^3 = v_i = \frac{O_i^2}{\sum_{j=1}^2 O_j^2}. \quad (3.30)$$

- **Couche 4** : Chaque neurone i de cette couche est relié à un neurone de normalisation correspondant et aux entrées initiales du réseau. Il calcule le conséquent pondéré de la règle.

$$O_i^4 = O_i^3 \times f_i = O_i^3(p_i x_1 + q_i x_2 + r_i), i = 1, 2, \quad (3.31)$$

où O_i^3 est la sortie de la couche 3, et p_i, q_i, r_i sont des paramètres de sortie de la règle i .

- **Couche 5** : Elle contient un seul neurone qui fournit la sortie du réseau *ANFIS* en calculant la somme des sorties de tous les neurones de défuzzification.

$$O_1^5 = y = \sum_{i=1}^2 O_i^4. \quad (3.32)$$

L'apprentissage, à partir d'un ensemble de données, concerne l'estimation des paramètres prémisses et conséquents, la structure du réseau étant fixée. L'algorithme d'apprentissage commence par construire un réseau initial, ensuite on applique une méthode d'apprentissage par rétro-propagation de l'erreur entre la sortie O_1^5 et la sortie désirée O^d qui est définie par la relation.

$$e = (O_1^5 - O^d). \quad (3.33)$$

Shing et Jang [94] ont proposé d'utiliser une règle hybride d'apprentissage du réseau *ANFIS* qui combine un algorithme de descente du gradient avec une estimation par moindres carrées dans le but de minimiser l'erreur e qui sera utilisée pour adapter les poids.

3.5.1.2 Technique de pronostic basée sur la méthode *ANFIS*

Soient le vecteur $\widehat{X}_k = [\widehat{x}_{k,1} \cdots \widehat{x}_{k,D}]^\top$ et $p^{E_i}(k)$ les vecteurs d'entrée du réseau *ANFIS*. Les composantes du vecteur \widehat{X}_k sont calculées sur une fenêtre glissante de taille N_{fen} par :

$$\widehat{x}_{k,v} = \frac{1}{N_{fen}} \sum_{j=k-N_{fen}+1}^k x_{j,v}. \quad (3.34)$$

avec $x_{k,v}$ la valeur brute de la composante v du vecteur X_k .

La probabilité \widehat{p}^{E_i} est la sortie prédite par le réseau *ANFIS*. Cette phase d'apprentissage permet d'estimer les paramètres prémisses et conséquents du réseau. Ces paramètres sont utilisés pour prédire l'état futur du système lorsqu'il est exploité dans les mêmes conditions que pendant la phase d'apprentissage.

- L'erreur quadratique moyenne est définie par :

$$E = \frac{1}{2N_{fen}} \sum_{l=1}^{N_{fen}} (\widehat{p}^{E_i}(l) - p^{E_i}(l))^2. \quad (3.35)$$

La vraie valeur de la probabilité p^{E_i} est obtenue par la relation (3.24).

L'expression de E est une fonction objective qui constitue un premier critère d'optimisation pour les modèles *TSK*. Ce critère est utilisé pour un apprentissage hors ligne en exploitant l'ensemble de données d'apprentissage [78, 93]. Les paramètres conséquents (p_i, q_i, r_i) du réseau *ANFIS* sont déterminés par la méthode des moindres carrés et les paramètres prémisses du réseau *ANFIS* (par exemple la moyenne et l'écart type d'une fonction gaussienne) sont définis par :

$$\begin{cases} m_i(k) = m_i(k-1) + \eta_m \Delta m_i & \text{avec } \Delta m_i = -\frac{\partial E}{\partial m_i} = \left[-\frac{\partial E}{\partial O_1^5}\right] \left[\frac{\partial O_1^5}{\partial m_i}\right], \\ \sigma_i(k) = \sigma_i(k-1) + \eta_\sigma \Delta \sigma_i & \text{avec } \Delta \sigma_i = -\frac{\partial E}{\partial \sigma_i} = \left[-\frac{\partial E}{\partial O_1^5}\right] \left[\frac{\partial O_1^5}{\partial \sigma_i}\right], \end{cases} \quad (3.36)$$

avec η_m et η_σ des constantes positives appelées taux d'apprentissage.

L'exemple de la figure 3.18.a correspond à l'évolution de la classe normale vers une classe anormale. La figure 3.18.b représente la probabilité réelle p^{E_i} (trait continu) et la probabilité prédite \widehat{p}^{E_i} par *ANFIS* (trait discontinu), après avoir ajusté les poids des neurones, c'est-à-dire après la phase d'apprentissage. Le réseau de neurones est ensuite utilisé pour prédire l'évolution de la dégradation sur un horizon de prédiction h [71].

- L'erreur quadratique à chaque instant k est définie par :

$$E_k = \frac{1}{2} e_k^2 = \frac{1}{2} (\widehat{p}^{E_i}(k) - p^{E_i}(k))^2. \quad (3.37)$$

L'erreur quadratique E_k constitue un deuxième critère d'optimisation. Ce critère est en général utilisé pour un apprentissage en ligne à chaque fois qu'un nouveau point arrive [79]. A chaque instant k , l'erreur quadratique E_k est calculée. Les paramètres prémisses et conséquents sont mis à jour d'une manière récursive. Les paramètres prémisses sont mis à jour selon la relation (3.36), en remplaçant l'erreur quadratique moyenne E par l'erreur quadratique E_k .

La prédiction de p^{E_i} sur un horizon de prédiction h est réalisée en associant le vecteur d'entrée du réseau \widehat{X}_{k-h} à la sortie désirée p^{E_i} (voir figure 3.19). Dans ce cas, l'erreur permettant de faire des mises à jour des paramètres du réseau est donnée par la relation :

$$\widehat{e}_k = p^{E_i}(k+h) - \widehat{p}^{E_i}(k+h), \quad \forall k > h, \quad (3.38)$$

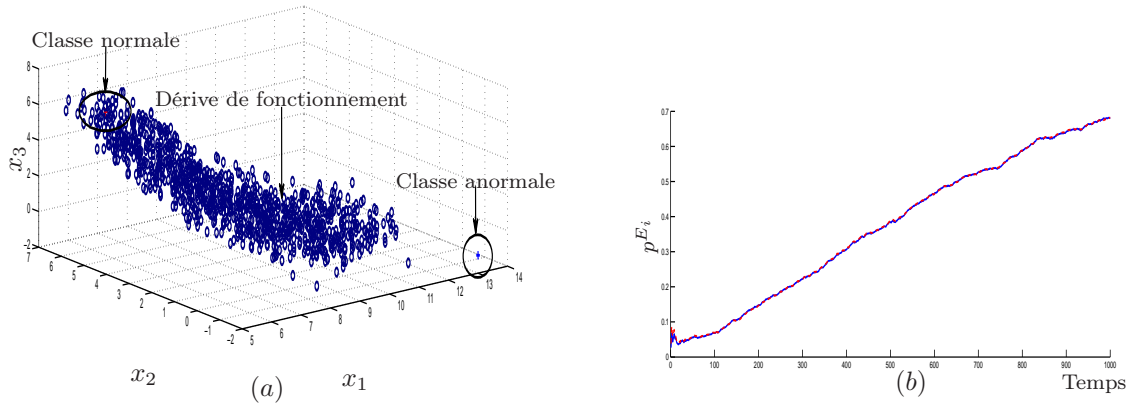


FIGURE 3.18 – Approximateur $ANFIS$, (a) - Evolution de la classe normale vers la classe anormale, (b) - p^{E_i} réelle et \hat{p}^{E_i} prédite sont confondues.




FIGURE 3.19 – Prédiction de l'état futur en utilisant $ANFIS$.

Le réseau $ANFIS_1$ permet d'estimer la probabilité $\hat{p}^{E_i}(k)$ et le réseau $ANFIS_2$ a pour rôle de projeter l'état courant du système dans le futur en estimant la probabilité $\hat{p}^{E_i}(k+h)$ sur un horizon h .

Le principal inconvénient de l'approche de pronostic par apprentissage réside dans l'acquisition et la couverture des données d'apprentissage par le réseau $ANFIS_1$. La prédiction par la méthode $ANFIS$ exige une base d'apprentissage exhaustive. Or, rien ne garantit l'exhaustivité de la base d'apprentissage. Pour cette raison, nous proposons d'utiliser une approche de pronostic qui ne nécessite pas une connaissance exhaustive du système. Les paramètres de cette approche doivent être enrichis et mis à jour au fur et à mesure que les données arrivent. Cette technique est basée sur l'approche de pronostic par analyse de tendance, que nous présenterons par la suite.

3.5.2 Pronostic par analyse de tendance

Les approches de pronostic par analyse de tendance sont implantées sur des systèmes dont les défaillances arrivent à la suite d'une dégradation progressive [56]. Cependant, ces approches nécessitent une connaissance *a priori* des modes de fonctionnement normaux et anormaux de chaque composant du procédé [63]. L'utilisation des indicateurs de dégradation est la caractéristique particulière des approches de pronostic par analyse de tendance.

La gamme des outils utilisés dans cette approche inclut les outils de prévision des séries temporelles. Une série temporelle peut être définie par une suite d'occurrences d'une variable aléatoire $\{X_k\}_{k \in \mathbb{N}}$ ordonnée dans le temps, k étant l'instant d'apparition de la donnée X_k . Les intervalles d'apparition des données sont constants. Dans le contexte du pronostic, l'intérêt des approches de pronostic par analyse de tendance est de modéliser une évolution à partir de l'estimation faite sur un ensemble d'observations issues du procédé et de prévoir son état futur en continu.

Les techniques de régression sont les plus utilisées pour la prédiction des séries temporelles [53]. Les avantages principaux de ces techniques résident dans leur capacité à modéliser les séries temporelles correspondant à la trajectoire de dégradation du procédé ou de ses composants. Les avantages des techniques de régression résident également dans leur capacité d'adaptation, leur rapidité de mise en œuvre et leur possible utilisation en temps réel. La technique de régression vise à déterminer une fonction de temps $\mathcal{F}(k)$ approchant au mieux l'allure d'une série temporelle $\{X_k\}_{1 \leq k \leq N}$, avec N le nombre d'observations. Cette approche consiste à supposer que la fonction $\mathcal{F}(k)$ est complètement définie par un jeu de paramètres $\Theta = [\theta_n \ \theta_{n-1} \ \dots \ \theta_0] \in \mathbb{R}^{n+1}$. L'équation ci-dessous est un exemple d'une série temporelle décrite par un modèle polynômial.

$$\mathcal{F}_\Theta(k) = \theta_n k^n + \dots + \theta_1 k + \theta_0. \quad (3.39)$$

Cette méthode s'applique à n'importe quel type de fonction. Elle consiste à déterminer les paramètres n et Θ en minimisant un critère quadratique normalisée E_n . La valeur de E_n correspond à la somme des erreurs de prédiction en pourcentage en fonction du degré du polynôme.

$$E_n = \sum_{j=1}^N \frac{(X_j - \mathcal{F}_\Theta(j))^2}{\mathcal{F}_\Theta(j)}. \quad (3.40)$$

La figure 4.16 illustre le choix de la valeur de optimale n correspondant au minimum de la somme des erreurs normalisée.




FIGURE 3.20 – Somme des erreurs de prédiction en pourcentage en fonction du degré du polynôme.

3.6 Approches de pronostic basées sur un modèle de régression prédictif

Nous rappelons que l'utilité d'un processus de pronostic est intimement liée à sa nécessité d'approximer et de prédire l'état futur de la dégradation d'un composant ou d'un équipement du procédé [71, 101]. L'approche de pronostic de défaillance que nous proposons dans ce mémoire a pour objectif d'approximer les séries temporelles correspondant aux indicateurs de dégradation et de prédire leur état futur en temps réel. Cette approche de pronostic est basée sur la technique de régression polynômiale et l'algorithme des Moindres Carrés Récursifs (*MCR*). Elle est appliquée sur les indicateurs de dégradation $p^{E_i}(k)$ fournis par le processus de supervision, comme illustré sur la figure 3.21. Le module de supervision a pour objectif de fournir, à chaque instant k la probabilité $p^{E_i}(k)$. Le processus de pronostic permet de projeter l'état courant du composant i dans le futur en estimant $\hat{p}^{E_i}(k+h)$.

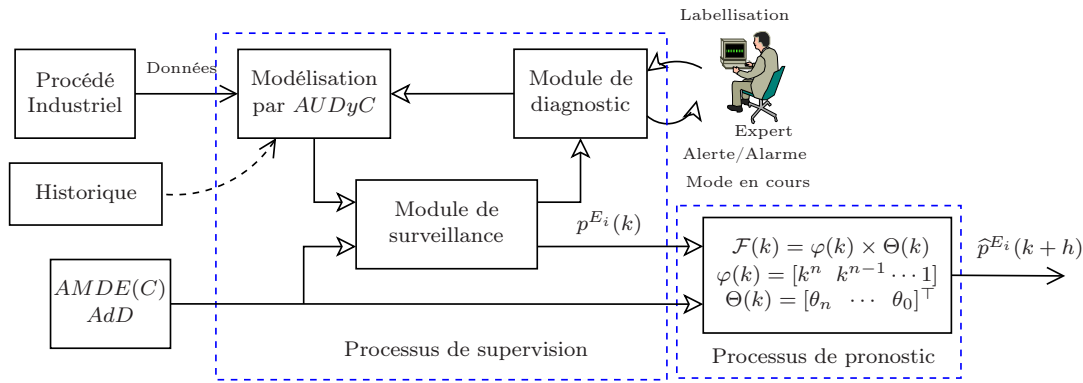


FIGURE 3.21 – Approche de pronostic basée sur la technique de régression polynômiale.

Pour pronostiquer l'état futur du système ou de ses composants, nous proposons de modéliser la tendance de chaque indicateur p^{E_i} par une fonction polynômiale de degré n . En effet, il existe trois types de trajectoires (abaques) possibles pour une dégradation : trajectoire linéaire, trajectoire convexe ou trajectoire concave, comme montré sur la figure 3.22.




FIGURE 3.22 – Tendances de dégradation possible.

Les coefficients de la fonction polynômiale sont mis à jour par la méthode des *MCR* [73].

Dans ce chapitre, deux méthodes d'approximation de la série temporelle $p^{E_i}(k)$ sont proposées pour prédire l'état futur des composants sur un horizon.

L'horizon de prédiction est choisi en fonction de la dynamique du système. L'horizon de prédiction peut être également choisi en fonction nécessaires pour la disponibilité des équipements de maintenance, lorsque la maintenance est assurée par une entreprise extérieure.

3.6.1 Première approche de prédiction

Nous cherchons à prévoir l'état futur du système sur un horizon h , quelle que soit la forme de la trajectoire décrite par les indicateurs de détérioration. La figure 3.23 illustre l'exemple de projection de l'état courant d'un composant du système sur un horizon de prédiction h .

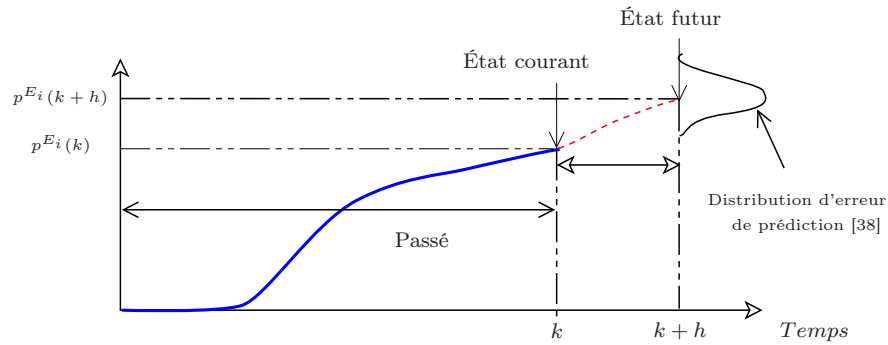


FIGURE 3.23 – Exemple de prédiction de l'état futur.

L'approche de pronostic que nous proposons est basée sur une modélisation des tendances de dégradation par une fonction polynômiale $\mathcal{F}(k)$ de degré n définie par l'expression suivante :

$$\begin{cases} \mathcal{F}(k) = \varphi(k) \Theta(k), \\ \varphi(k) = [k^n \ k^{n-1} \ \dots \ k^0], \\ \Theta(k) = [\theta_n \ \theta_{n-1} \ \dots \ \theta_0]^\top. \end{cases} \quad (3.41)$$

Le vecteur Θ est déterminé en temps réel par la méthode des *MCR* en utilisant les probabilités réelles $\mathbf{P}_i = [p^{E_i}(1) \ \dots \ p^{E_i}(k)]^\top$ extraites du système (voir relation 3.24).

La méthode des Moindres Carrés Récursifs pour calculer le vecteur Θ est définie par :

$$MCR : \begin{cases} K(k) = \frac{\mathcal{P}(k) \varphi(k)^\top}{1 + \varphi(k) \mathcal{P}(k) \varphi(k)^\top}, \\ \Theta(k) = \Theta(k-1) + K(k)(p^{E_i}(k) - \varphi(k) \Theta(k-1)), \\ \mathcal{P}(k) = \mathcal{P}(k-1) - \frac{\mathcal{P}(k-1) \varphi(k)^\top \varphi(k) \mathcal{P}(k-1)}{1 + \varphi(k) \mathcal{P}(k-1) \varphi(k)^\top}, \end{cases} \quad (3.42)$$

avec $\varphi(k) = [k^n \ k^{n-1} \ \dots \ 1]$, h l'horizon de prédiction, $\mathcal{P}(k)$ la variance et $K(k)$ est le gain d'adaptation.

La fonction polynômiale est ensuite utilisée afin de pronostiquer l'état futur du système. L'approche de pronostic que nous avons proposé afin de prédire la situation future du composant

i sur un horizon h (instant $k + h$) est donnée par la relation suivante.

$$\hat{p}^{E_i}(k+h) = \begin{cases} 0 & \text{si } \mathcal{F}(k+h) < 0, \\ 1 & \text{si } \mathcal{F}(k+h) \geq 1, \\ \mathcal{F}(k+h) = \varphi(k+h) \Theta(k) & \text{sinon} \end{cases} \quad (3.43)$$

Pour trouver les paramètres optimaux Θ , la méthode a besoin de minimiser l'erreur e entre les données p^{E_i} réelles du système et les données \hat{p}^{E_i} prédites.

$$e = \sum_{l=1}^k (p^{E_i}(l) - \hat{p}^{E_i}(l))^2. \quad (3.44)$$

Nous souhaitons par la suite calculer l'erreur de prédiction, pour cela, nous calculons la différence entre la valeur courante de $p^{E_i}(k)$ et la valeur de $\hat{p}^{E_i}(k)$ qui a été prédite à l'instant $k - h$.

La figure 3.24.a représente l'évolution du mode de fonctionnement normal du composant i vers le mode de fonctionnement anormal de celui-ci. La figure 3.24.b représente la valeur "réelle" de p^{E_i} du composant et la valeur prédite \hat{p}^{E_i} sur un horizon de prédiction. La figure 3.25.b représente la valeur p^{E_i} "réelle" du composant et la valeur prédite \hat{p}^{E_i} sur un horizon de prédiction $h = 40$.

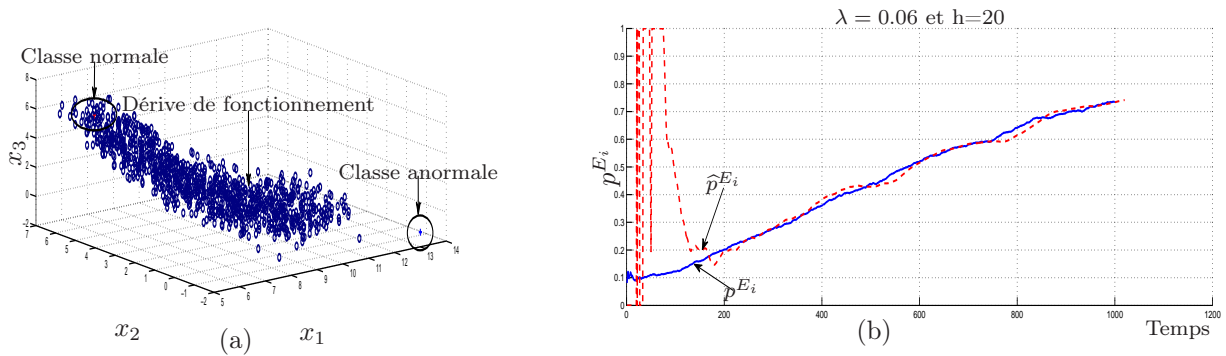


FIGURE 3.24 – Pronostic de défaillance basé sur la technique de régression, avec $h = 20$.

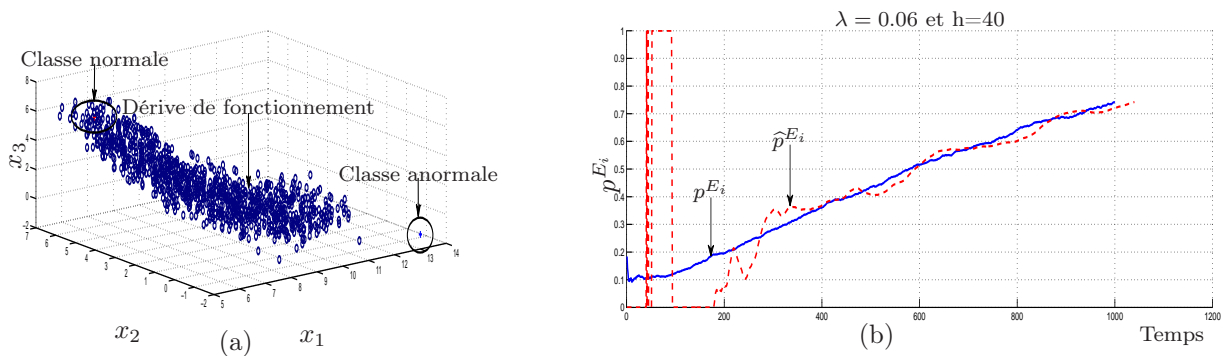


FIGURE 3.25 – Pronostic de défaillance basé sur la technique de régression, avec $h = 40$.

Les erreurs de prédiction pour les horizons $h = 20$ et $h = 40$ sont illustrées à la figure 3.26. Nous constatons que les erreurs de prédiction convergent vers zéro, plus rapidement lorsque

l'horizon est petit. Bien entendu, plus l'horizon est grand, plus la précision du pronostic est faible.




FIGURE 3.26 – Erreurs de prédiction pour deux horizons, $h = 20$ et $h = 40$.

3.6.2 Deuxième approche de prédiction

La deuxième méthode de pronostic ne peut être applicable que lorsque l'instant courant k est supérieur ou égal à $h + 1$. Cette méthode consiste à modéliser les p^{E_i} grâce à une fonction polynômiale $\mathcal{G}(k)$ de degré n , définie par la relation suivante.

$$\begin{cases} \mathcal{G}(k+h) = \varphi(k) \Theta'(k), \\ \Theta'(k) = f(\Theta'(k-1), p^{E_i}(k), \varphi(k-h)). \end{cases} \quad (3.45)$$

Le vecteur Θ' est estimé en temps réel par la méthode des *MCR* définie selon la relation (3.42), mais en remplaçant le vecteur $\varphi(k)$ par le vecteur $\varphi(k-h)$.

A chaque instant k , la prédiction de p^{E_i} sur un horizon h consiste à calculer le vecteur $\Theta'(k)$ en temps réel. La prédiction de $\hat{p}^{E_i}(k+h)$ est réalisée à partir de la fonction $\mathcal{G}(k+h)$ selon la relation suivante.

$$\hat{p}^{E_i}(k+h) = \begin{cases} 0 & \text{si } \mathcal{G}(k+h) < 0, \\ 1 & \text{si } \mathcal{G}(k+h) \geq 1, \\ \mathcal{G}(k+h) = \varphi(k) \Theta'(k) & \text{sinon.} \end{cases} \quad (3.46)$$

Le vecteur d'erreur de prédiction ε'_{Θ} est calculé en comparant les valeurs des probabilités prédites \hat{p}^{E_i} avec les probabilités d'occurrence réelles p^{E_i} selon la relation :

$$\varepsilon'_{\Theta}(k+h) = (p^{E_i}(k+h) - \hat{p}^{E_i}(k+h))^2. \quad (3.47)$$

La figure 3.27 représente la probabilité réelle p^{E_i} et la probabilité prédite \hat{p}^{E_i} par la deuxième approche de pronostic.

Les erreurs de prédiction de cette deuxième méthode sont représentées à la figure 3.28. Nous constatons également l'influence de l'horizon de prédiction sur la performance de la méthode de pronostic. Avec cette deuxième méthode, les erreurs de prédiction tendent également vers zéro.

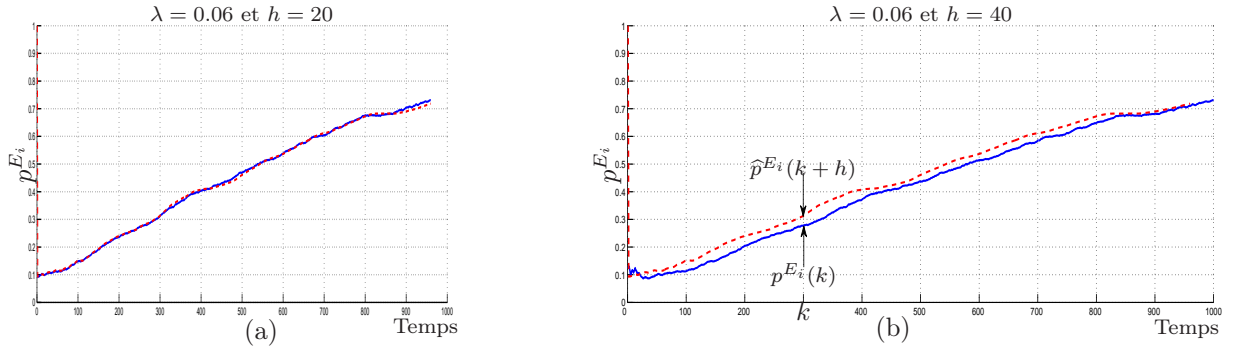


FIGURE 3.27 – Pronostic de défaillance basé sur la technique de régression : (a) - prédiction sur un horizon $h = 20$ et (b) - prédiction sur un horizon $h = 40$.




FIGURE 3.28 – Erreurs de prédiction pour deux horizons, $h = 20$ et $h = 40$.

Distribution d'erreurs de prédiction

Pour étudier la dispersion des erreurs de prédiction, nous introduisons l'erreur de prédiction en pourcentage. Pour la première méthode de pronostic cette erreur de prédiction en pourcentage est donnée par :

$$EPP_{\theta,k} = \frac{p^{E_i}(k+h) - \hat{p}^{E_i}(k+h)}{p^{E_i}(k+h)} \times 100. \quad (3.48)$$

et pour la seconde méthode de pronostic cette erreur de prédiction en pourcentage est donnée par :

$$EPP_{\theta',k} = \frac{p^{E_i}(k+h) - \hat{p}'^{E_i}(k+h)}{p^{E_i}(k+h)} \times 100. \quad (3.49)$$

Nous proposons de formaliser ces erreurs sous un formalisme gaussien comme défini par les relations (3.50) et (3.51). Les paramètres σ_ζ , m_ζ , $\sigma_{\zeta'}$ et $m_{\zeta'}$ des relations (3.50) et (3.51) sont calculés à chaque instant $k \geq h$. Ainsi, pour chaque nouvelle prédiction de $I_{d,i}$, la distribution des erreurs est réévaluée. Finalement, ces distributions d'erreurs sont utilisées afin de fournir des indicateurs sur la dispersion des erreurs de prédiction, afin de déterminer la méthode la plus

fiable.

$$F_{\zeta} = \frac{1}{\sigma_{\zeta}\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{\zeta - m_{\zeta}}{\sigma_{\zeta}}\right)^2\right), \quad (3.50)$$

$$F_{\zeta'} = \frac{1}{\sigma_{\zeta'}\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{\zeta' - m_{\zeta'}}{\sigma_{\zeta'}}\right)^2\right), \quad (3.51)$$

avec $\zeta = \frac{\varepsilon_{\theta}}{\mathbf{P}_i[h+k_1:S]} 100$ et $\zeta' = \frac{\varepsilon'_{\theta}}{\mathbf{P}_i[h+k_1:S]} 100$, et m_{ζ} et σ_{ζ} , $m_{\zeta'}$ et $\sigma_{\zeta'}$ sont les moyennes et les écarts types des vecteurs d'erreurs en pourcentage ζ et ζ' .

Les deux approches de pronostic que nous avons proposées sont testées sur une p^{E_i} associée à la classe évolutive définie sur la figure 3.24, en considérant les horizons suivants : $h = 20$ et $h = 40$. Quel que soit l'horizon considéré, la *courbe*₂ de la figure 3.29.a et 3.29.b est issue d'un modèle de prédiction plus fiable que celui du modèle donnant la *courbe*₁ de la figure 3.29.a et 3.29.b. En effet, la dispersion de la *courbe*₂ est moins importante que la *courbe*₁ sur les deux horizons. La *courbe*₂ est issue de la deuxième approche de pronostic, donc cette approche présente des estimations les plus fiables.




FIGURE 3.29 – Dispersion des erreurs de prédiction : (a) - pour $h = 20$ et (b) - pour $h = 40$.

Chacune des deux approches de pronostic de défaillance que nous avons proposées a un avantage et un inconvénient. L'avantage de la première approche est qu'elle peut être mise en œuvre à l'instant $k = 1$. Cependant, cette première approche est moins fiable à cause de la dispersion d'erreurs. L'avantage de la deuxième approche est qu'elle est plus fiable que la première approche. Cependant, elle ne peut être mise en œuvre qu'à l'instant $k > h$, avec h l'horizon de prédiction. La deuxième méthode de pronostic est retenue dans le manuscrit pour ses performances. Elle est illustrée sur un système réel dans le chapitre 4.

3.7 Conclusion

Dans ce chapitre, nous avons tout d'abord présenté les différents phénomènes de dégradation, ainsi que des outils de détection de dérives rapides et lentes. Les dérives lentes sont des dérives difficilement détectables par des outils de détection classiques. Pour répondre à ce problème, nous avons proposé une technique de détection de dérives lentes basée sur le calcul des taux de dérive. Cette technique est illustrée sur des données issues d'un système réel. Dans la suite

du chapitre, nous avons proposé des méthodes d'estimation des indicateurs de dégradation en fonction des caractéristiques des modes de fonctionnement. Elles consistent à suivre en ligne l'état de dégradation du système. Ces indicateurs sont ensuite exploités par le processus de pronostic de défaillance afin de prédire l'état futur du système. La démarche de mise en œuvre pour le pronostic est basée sur le couplage des méthodes d'analyse de défaillance et d'un processus de supervision des *SDE*.

Dans cette démarche, la méthode d'analyse de défaillance de type *AMDEC* est utilisée pour recenser l'ensemble des composants du système, leurs modes de défaillance et leur effet sur le système. A partir de cette étude, un arbre de défaillance (*AdD*) du procédé est construit, permettant d'obtenir l'interaction entre les différents modes de défaillance et en utilisant les portes logiques OU et/ou ET. Nous avons ensuite proposé des méthodes permettant d'estimer les probabilités d'occurrence des événements de l'arbre de défaillance en temps réel. Ces méthodes sont basées sur les indicateurs développés à partir des pourcentages de la distance effectuée par les modes de fonctionnement dégradés, c'est-à-dire les classes évolutives, en direction des classes de défaillance.

Par la suite, nous avons présenté les différentes approches de pronostic de défaillance. Parmi ces approches, une a retenu notre attention : l'approche guidée par les données, en particulier le pronostic par analyse de tendance. Cette technique est particulièrement intéressante pour notre problématique. En effet, elle est implantée sur des systèmes dont les défaillances arrivent à la suite d'une dégradation progressive. Cependant la mise en œuvre nécessite une connaissance *a priori* des modes de fonctionnement normaux et anormaux de chacun des composants du système. Les approches de pronostic de défaillance que nous avons proposées exploitent les informations passées et présentes sur l'état de fonctionnement du système. Ces informations sont fournies par le processus de supervision en continu. Les approches de pronostic proposées dans ce chapitre ont permis, d'une part de modéliser les tendances de dégradation des composants par des polynômes et, d'autre part de prédire l'état futur du système ou de ses composants sur des horizons de temps donnés. La modélisation des tendances de détérioration par un polynôme, nous offre l'avantage de considérer le pronostic en ligne pour chaque système ou chaque composant du système. Cette approche est illustrée dans le cadre d'un système de thermorégulation dans le chapitre 4.

4

Application à un système de thermorégulation

4.1 Introduction

L'étude effectuée tout au long de ce mémoire nous a amené à proposer une architecture de maintenance prévisionnelle de systèmes dynamiques évolutifs (systèmes non-stationnaires). La mise en œuvre de cette architecture s'appuie d'une part, sur une modélisation précise de connaissances expertes préexistantes (*AMDE*, Arbre de Défaillance) et d'autre part, sur la supervision et le pronostic de défaillance. Les méthodes de supervision présentées dans les chapitres précédents sont sensibles aux évolutions des caractéristiques intrinsèques du procédé. Nous avons montré quel est l'avantage d'utiliser un outil de supervision intégrant un module de modélisation. Notre choix de l'outil de modélisation s'est porté sur l'*AUDyC* pour sa capacité à modéliser des données issues de systèmes dynamiques évolutifs. Parmi les approches de pronostic de défaillance présentées dans le chapitre 3, nous avons choisi l'approche de pronostic de défaillance basée sur l'analyse de tendance en particulier la technique de régression. L'avantage de cette approche de pronostic réside dans sa simplicité de mise en œuvre et sa capacité à réaliser une prédiction de séries temporelles en temps réel.

Tous les outils présentés dans les chapitres précédents pour la mise en œuvre d'une stratégie de maintenance prévisionnelle sont illustrés dans ce chapitre sur un système réel. L'architecture de maintenance prévisionnelle proposée est appliquée sur un système de thermorégulation. Le thermorégulateur est un procédé très utilisé dans plusieurs applications industrielles ⁸. La mise en œuvre d'une stratégie de maintenance prévisionnelle du thermorégulateur nécessite une approche de supervision capable de représenter en temps réel les données provenant du système en termes

8. www.vulcanic.com

de modes de fonctionnement. Elle doit être également capable de détecter des dérives rapides et lentes des modes de fonctionnement. Les dérives lentes sont des dérives difficilement détectables, et leur détection tardive peut avoir des conséquences catastrophiques. Les techniques de détection présentées dans le chapitre 3 sont illustrées sur des scénarios de défaillances provoqués sur le thermorégulateur.

Dans ce chapitre, la description du thermorégulateur et son exploitation sont présentées dans la section 4.2. La problématique de la surveillance du thermorégulateur est présentée dans la section 4.3. L'outil de supervision du thermorégulateur utilisant un module de modélisation basé sur l'*AUDyC* est détaillé dans la section 4.4. Dans la section 4.5, les indicateurs de dégradation des composants du thermorégulateur sont présentés. Les méthodes d'estimation de probabilités d'occurrence de défaillance des composants soumis à des dérives lentes sont détaillées dans la section 4.6. Nous présentons enfin l'approche de pronostic de défaillance en ligne appliquée sur les données réelles issues du thermorégulateur dans la section 4.7. Pour finir, une stratégie de maintenance prévisionnelle est proposée dans la section 4.8.

4.2 Description du thermorégulateur

Un thermorégulateur permet de chauffer, de refroidir et de réguler un fluide caloporteur en boucle fermée. Dans notre application, il a pour tâche de maintenir c'est-à-dire de réguler la température, d'un moule (système client) par la circulation du fluide chauffé par le réchauffeur électrique et de refroidir le fluide par l'échangeur de chaleur via un échange de calories entre un circuit primaire et un circuit secondaire. Le thermorégulateur que nous disposons au sein de notre laboratoire est composé d'une pompe, d'un réchauffeur, de deux filtres en redondance passive, d'un échangeur et d'un vase d'expansion. Le réchauffeur électrique de 6 kW assure la montée et le maintien de la température du fluide à l'aide de résistances électriques. L'échangeur thermique d'environ 0.5 m², permet le refroidissement du fluide grâce à un circuit d'eau secondaire. Un groupe motopompe (avec variateur de vitesse) pouvant assurer jusqu'à un débit maximum de 4 m³/h est utilisé pour permettre la circulation du fluide. Les filtres ont pour rôle de garantir que des particules ne se propagent pas avec le fluide en circulation. Le vase d'expansion permet de compenser l'augmentation du volume et la dilatation subie par le fluide entre la température ambiante et la température d'utilisation.

Pour surveiller la régulation de la température du fluide, le système thermorégulateur a été équipé des capteurs suivants : capteur de mesure de la puissance délivrée par le réchauffeur, capteur de mesure de la puissance injectée dans le système client, débitmètres, capteurs de niveau, capteurs de pression et capteurs de température. Le tout est relié à un PC équipé d'une carte d'acquisition National Instruments. Sur le PC, une interface spécifique a été développée en utilisant "Matlab". Les modules utilisés sont notamment les boîtes à outils "data acquisition" et "signal processing". Les données récupérées sur le PC sont exploitées par le processus de supervision du procédé.

4.3 Formulation du problème

Le thermorégulateur est soumis à des défaillances dont les plus fréquentes sont celles liées à un vieillissement ou à une dégradation lente de ses composants. Ces défaillances peuvent provoquer l'arrêt non programmé du thermorégulateur pour des actions de maintenance curative qui impliquent des temps d'indisponibilité importants et des coûts de maintenance importants. Une alternative intéressante consiste alors en la maintenance prévisionnelle du système basée d'une part sur le suivi en temps réel de l'état de fonctionnement des composants et d'autre part sur la prévision de la situation future du système ou de ses composants. Une analyse dysfonctionnelle du thermorégulateur de type *AMDE* (Analyse des Modes de Défaillance et de leurs Effets) a permis de déterminer les principaux composants du système soumis à des dérives lentes de fonctionnement. Les résultats non exhaustifs de l'*AMDE* du système sont représentés sur le tableau suivant.

Composant	Modes de défaillance	Causes	Effets
Pompe	Défaillance du moteur électrique.	Défaillance des composants.	Arrêt de la circulation d'eau dans le circuit chaud.
	Faible débit	Usure des engrenages	Diminution de la durée de vie du système, régulation inefficace
	Irrégularité du débit	Cavitation	Amplitude des écarts de température plus importante
Échangeur de chaleur	Débit faible coté froid.	Entartrage (eau) coté froid et chaud.	Pas de refroidissement du fluide.
Réchauffeur électrique	Résistance encrassée.	Encrassement et dépôt de tarte	L'eau contenue dans le circuit chaud n'est pas suffisamment chauffée.
	Coupure d'une ou plusieurs des trois résistances	Court-circuit	Perte de performance thermique du composant
Filtre	Colmatage	Colmatage progressif.	Pas de circulation d'eau.
	Rupture de la membrane filtrante	Vieillessement des membranes, présence de corps étranger	Passage du calcaire dans le circuit.

TABLE 4.1 – L'*AMDE* du circuit chaud du thermorégulateur.

Dans ce chapitre, nous nous intéressons aux dérives lentes de fonctionnement des composants du thermorégulateur, représentées en gras dans le tableau 4.1. Ces dérives sont difficilement détectables et leur détection tardive peut avoir des conséquences catastrophiques sur le système, le personnel et/ou l'environnement. C'est pour cette raison, que des capteurs ont été installés sur le système. Les capteurs installés sur le système permettent d'indiquer la pression en entrée et en sortie de chaque composant du thermorégulateur, comme montré sur la figure 4.1.

La surveillance des états de fonctionnement de ces composants est réalisée à partir des signaux

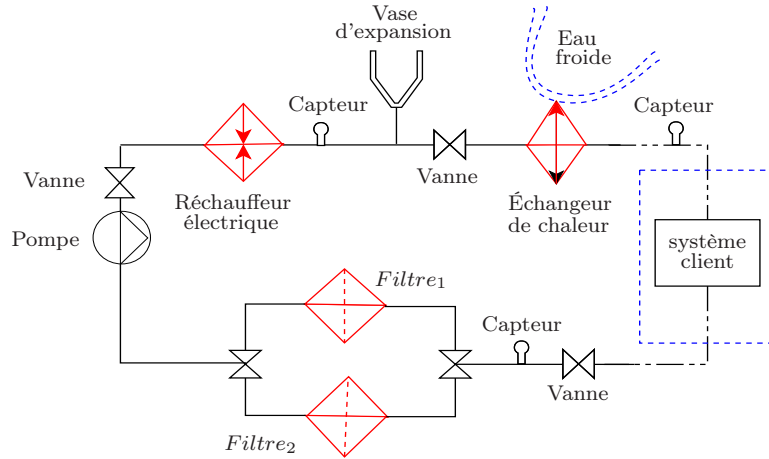


FIGURE 4.1 – Schéma du circuit chaud du thermorégulateur.

délivrés par les indicateurs x_r , x_e et x_f définis par la relation suivante.

$$\begin{cases} x_r = \frac{P_{\text{entrée réchauffeur}} - P_{\text{sortie réchauffeur}}}{\Delta P_{\text{pompe}}}, \\ x_e = \frac{P_{\text{entrée échangeur}} - P_{\text{sortie échangeur}}}{\Delta P_{\text{pompe}}}, \\ x_f = \frac{P_{\text{entrée filtre}} - P_{\text{sortie filtre}}}{\Delta P_{\text{pompe}}}, \end{cases} \quad (4.1)$$

où P est la pression d'entrée ou de sortie de chaque composant et $X_k = [x_r \ x_e \ x_f]^\top$ est le vecteur d'observation du thermorégulateur composé des trois indicateurs. L'indicateur x_r permet de surveiller le fonctionnement du réchauffeur, x_e permet de surveiller le fonctionnement de l'échangeur et x_f permet de surveiller le fonctionnement des filtres. Le choix de surveiller ces trois composants est fait à partir des résultats de l'analyse *AMDE* du procédé présentés sur le tableau 4.1. En effet, ces composants sont soumis à des dérives lentes. Nous cherchons à mettre en place un espace de décision permettant de détecter les principales dérives et défaillances relatives à l'entartrage des principaux composants (réchauffeur, échangeur, filtre). La dimension de l'espace de représentation est donc fixé avec $3D$, où chaque axe est sensible à la perte de pression d'un des composants.

Idéalement, les données obtenues via le vecteur X_k , sont réparties sur mode de fonctionnement normal et trois modes de fonctionnement anormaux correspondant à la défaillance de chaque composant, nous rappelons, seul les composants soumis à des encrassements sont traités dans ce chapitre. Les évolutions lentes des modes de fonctionnement des composants du système auront pour effet de faire évoluer progressivement les données de la classe normale vers la classe anormale correspondant à chaque composant. Un processus de supervision est constitué des modules de modélisation par *AUDyC*, de surveillance (suivi et détection) et de diagnostic.

4.4 Processus de supervision du thermorégulateur

Le processus de supervision du thermorégulateur est constitué d'un module de Modélisation par l'algorithme *AUDyC*, d'un module de suivi/détection et d'un module de diagnostic. La figure 4.2 illustre l'architecture d'un processus de supervision permettant de surveiller les composants du thermorégulateur soumis à des dérives lentes, identifiées par l'analyse dysfonctionnelle du procédé.




FIGURE 4.2 – Modules constituant le processus de supervision du thermorégulateur.

4.4.1 Modélisation par l'algorithme *AUDyC*

Le module de modélisation est au cœur de notre structure de supervision pour la mise en œuvre d'une stratégie de maintenance prévisionnelle des systèmes évolutifs. Cet outil de modélisation a deux rôles au sein du processus de supervision [58] :

- le premier rôle est de fournir une modélisation dynamique des modes de fonctionnement des composants du thermorégulateur. Ceux-ci sont modélisés au fur et à mesure de leur apparition et leur définition est mise à jour en continu.
- le second rôle est d'évaluer, pour chaque nouvelle observation caractérisant l'état de fonctionnement du procédé, ses degrés d'appartenance aux différents modèles de modes de fonctionnement existant.

L'entrée du module modélisation correspond à la présentation d'un vecteur d'observations caractéristiques de l'état de fonctionnement du procédé. Conformément à l'étude présentée dans le chapitre 1, le vecteur d'observations est constitué de valeurs sensibles à l'état de fonctionnement du système. Ces valeurs dans le cas du thermorégulateur sont obtenues à partir des mesures recueillies sur les composants soumis à des dérives lentes de fonctionnement.

La construction de l'espace de décision est réalisée par l'*AUDyC* dont les paramètres ont dû être fixés en accord avec les caractéristiques du mode de fonctionnement du thermorégulateur ainsi que des capteurs et actionneurs qui l'équipent. Plusieurs simulations ont permis de fixer ceux-ci. Pour chacun des composants, nous avons considéré que la défaillance maximum liée à l'entartrage correspond à une perte d'environ 20% de débit. Ainsi, les valeurs suivantes ont été fixées : $\mu_{\min} = 0.0081$; $\mu_{\max} = 0.01$; $\sigma_{ini} = 1.8$, $n_{amb} = 9$, $N_{C_{\min}} = 30$ et $N_{P_{\min}} = 25$, $N_{fen} = 90$. Ces paramètres ont été choisis de manière à n'obtenir que des classes uniquement représentées par un prototype.

L'acquisition des données a été faite à la période de 1s. Dans un premier temps, les données brutes sont filtrées à l'aide d'un filtre médian. Ce filtre a pour but d'éliminer les principaux pics de bruit impulsionnel générés par les organes de puissance du thermorégulateur. La taille du filtre médian a été fixée à 11 échantillons. Chaque nouvelle observation est ensuite traitée en ligne par le module de modélisation. Par la suite, les degrés d'appartenance de l'observation courante X_k aux différents modes connus sont calculés, et les paramètres caractéristiques du mode de fonctionnement auquel X_k est associé, sont mis à jour.

Les modèles utilisés pour la représentation des classes correspondantes aux modes de fonctionnement du système sont des modèles gaussiens. Chaque prototype P_j de la classe C_i est défini à l'aide d'un vecteur centre M_j et d'une matrice de covariance Σ_j . Les classes et les prototypes sont obtenus par apprentissage. Le degré d'appartenance à chaque prototype P_j connu est calculé de la façon suivante.

$$\begin{cases} \mu(X_k, P_j) = \exp\left(-\frac{d(X_k, P_j)^2}{2}\right), \\ d(X_k, P_j)^2 = (M_{P_j} - X_k)\Sigma_{P_j}^{-1}(M_{P_j} - X_k)^\top, \end{cases} \quad (4.2)$$

Les centres de classes ainsi que les valeurs propres de la matrice de covariance des quatre classes de référence obtenues par *AUDyC* sont présentées dans le tableau suivant 4.2. Les classes de référence sont :

- classe normal,
- classe de défaillance du réchauffeur,
- classe de défaillance de l'échangeur,
- classe de défaillance du filtre.

Le système thermorégulateur illustré sur la figure 4.1 est équipé des vannes permettant de simuler les défaillances ou l'encrassement des composants du système sans endommagée la maquette. Pour obtenir l'encrassement d'un composant, il faut fermer progressivement la vanne situé en aval du composant. Nous supposons dans ce chapitre d'application que le fonctionnement normal de la pompe et l'alimentation du système thermorégulateur en eau froide sont garanties.

Mode	Normal	Réchauffeur	Échangeur	Filtre
Centre	$M = \begin{pmatrix} -0.895 \\ 0.02 \\ -0.075 \end{pmatrix}$	$M = \begin{pmatrix} -0.9347 \\ 0.0105 \\ -0.0418 \end{pmatrix}$	$M = \begin{pmatrix} -0.899 \\ -0.0435 \\ -0.0424 \end{pmatrix}$	$M = \begin{pmatrix} -0.8968 \\ -0.0362 \\ -0.0770 \end{pmatrix}$
Valeurs propres	$\lambda_\Sigma = \begin{pmatrix} 0.013 \\ 0.018 \\ 0.013 \end{pmatrix}$	$\lambda_\Sigma = \begin{pmatrix} 0.01 \\ 0.01 \\ 0.11 \end{pmatrix}$	$\lambda_\Sigma = \begin{pmatrix} 0.1 \\ 0.12 \\ 1 \end{pmatrix}$	$\lambda_\Sigma = \begin{pmatrix} 0.1 \\ 0.1 \\ 1.1 \end{pmatrix}$

TABLE 4.2 – Caractéristiques des modes de fonctionnement.

La figure 4.3 illustre l'espace de décision obtenu lorsque la classe normale et les classes de défaillances de trois composants ont été apprises.

Le principe de module de modélisation par *AUDyC* est d'utiliser un apprentissage en ligne permettant de modéliser en continu l'espace de décision. Si l'adaptation des prototypes est décidée




FIGURE 4.3 – Espace de décision des composants du thermorégulateur.

par l'une des règles de l'étape de classification de l'*AUDyC* (*cf* : *chapitre 2*), celle-ci est calculée de façon récursive. Pour ce faire, nous définissons une fenêtre glissante de taille N_{fen} sur les observations associées à un prototype. L'influence de la taille de fenêtre sur la définition des prototypes est détaillée dans [58]. Puis tous les paramètres du prototype sont déterminés de façon itérative en fonction de sa cardinalité par les équations (2.46) et (2.47). Le mode de fonctionnement dans lequel le système évolue est déterminé par le processus de diagnostic.

4.4.2 Diagnostic du thermorégulateur

Le module de diagnostic a pour objectif d'identifier et de caractériser le mode de fonctionnement auquel l'état de fonctionnement du procédé ressemble le plus. Cette caractérisation permet d'identifier le passage d'un mode de fonctionnement à un autre, ou d'avertir l'utilisateur de l'éventuelle apparition d'un nouveau mode de fonctionnement. Pour ce second point, nous assistons en réalité à un échange entre le module de diagnostic et un expert du procédé, visant à labelliser les nouveaux modèles en termes de modes de fonctionnement. Ce dialogue a donc pour objectif, d'une part, d'informer l'utilisateur sur l'état de fonctionnement du procédé, et d'autre part, de parfaire la connaissance du processus de supervision afin d'améliorer le diagnostic futur.

- La première tâche du module de diagnostic vise à définir, à tout instant, le mode de fonctionnement probable du procédé en fonction des degrés d'appartenance aux différents modèles existants. L'analyse des degrés d'appartenance par le module de diagnostic permet d'identifier le mode de fonctionnement courant. Parmi les différents gabarits de fonctions d'appartenance, nous avons retenu la fonction exponentielle (4.2) pour notre application. Cette fonction est la plus simple et la plus employée. Elle est basée généralement sur la distance de Mahalanobis. En effet, cette fonction a l'avantage de limiter le risque de mauvais diagnostic. Lorsqu'une observation se situe dans une région éloignée des modèles existants (degré d'appartenance proche de 0 quel que soit le modèle considéré) ou à proximité de plusieurs modèles (degrés d'appartenance similaires pour plusieurs modèles), l'exploitation de cette fonction permet d'éviter de lui associer un mode de fonctionnement erroné.

- Au-delà de cette tâche d'identification du mode de fonctionnement actuel du procédé, le module de diagnostic a pour rôle d'informer au plus tôt l'utilisateur, du mode de fonctionnement vers lequel évolue le procédé. Cet aspect du diagnostic est lié à la détection de dérives qui a été réalisée par le module de surveillance (suivi/détection). Le module de diagnostic exploite alors les différents résultats de détection pour caractériser l'évolution de l'état de fonctionnement. Le diagnostic est alors traduit de deux manières :

- dérive d'un mode de fonctionnement vers un autre mode de fonctionnement connu et identification de ce dernier,
- dérive d'un mode de fonctionnement vers un autre mode de fonctionnement inconnu.

- La troisième tâche du module de diagnostic vise à valider la caractérisation d'un éventuel nouveau mode de fonctionnement suite à la création d'un nouveau modèle par le module de modélisation. En effet, nous avons vu qu'en fonction des observations qui lui sont présentées, le module de modélisation peut être amené à créer une nouvelle classe caractérisée par un nouveau prototype, suite notamment à la stabilisation des observations dans une région donnée. Le module de diagnostic a donc pour rôle d'informer l'utilisateur de la création de cette nouvelle classe caractérisant un éventuel nouveau mode de fonctionnement. Celui-ci décide alors de valider ou non la création de cette classe. Dans l'affirmative, un expert du procédé doit labelliser ce nouveau modèle en terme de mode de fonctionnement et ainsi permettre l'actualisation de la base de connaissance. Les modes de fonctionnement existant dans la base de connaissance peuvent évoluer au cours du temps, la détection est assurée par le module de surveillance.

4.4.3 Détection des dérives

Le module de détection utilise les informations provenant du module de modélisation pour détecter tout changement de comportement des composants du système. Ce changement peut être brutal ou progressif. Les changements progressifs peuvent être rapides ou lents. Les tests statistiques tels que le *CUSUM*, le test de *Shewart* ou le *EWMA* peuvent être utilisés pour la détection des évolutions abruptes (*cf* : chapitre 1). Ces tests peuvent être également appliqués directement sur les observations ou sur leurs degrés d'appartenance aux différents modes de fonctionnement, mais l'outil de détection sera très sensible aux bruits.

Dans ce chapitre d'application, nous allons appliquer les techniques de détection des défaillances progressives, sur des données de simulation et des données extraites du procédé réel.

4.4.3.1 Détection des dérives rapides

Pour détecter des dérives rapides, une technique de régression a été proposée dans le chapitre 3 afin de modéliser la direction et la vitesse caractérisant la trajectoire des observations. Le critère de détection de ces dérives consiste à estimer à chaque instant l'angle Φ_k formé entre deux vecteurs de vitesse consécutifs V_k et V_{k-1} . Les vecteurs vitesse sont mémorisés dans une fenêtre glissante $\Psi_\Gamma = [V_{k-\Gamma+1} \cdots V_k]$ de taille Γ . Lorsqu'une dérive rapide apparaît, tous les vecteurs vitesse contenus dans Ψ_Γ s'orientent successivement dans le même sens que la dérive et

l'angle entre deux vecteurs consécutifs devient de plus en plus petit. Si la valeur Γ est petite, la probabilité de fausse alarme est importante, tandis qu'un Γ très grand entraîne des retards à la détection.

Pour appliquer l'outil de détection des dérives rapides, nous proposons de considérer le cas simple d'un réservoir soumis à un encrassement de ces parois. Il s'agit d'un réservoir composé d'une partie conique et d'une partie cylindrique, comme illustré figure 4.5. Il est équipé de deux vannes TOR (Tout Ou Rien) qui permettent de l'alimenter et de le vidanger.




FIGURE 4.4 – Système réservoir.

Pour surveiller en continu l'état de fonctionnement du réservoir, nous utilisons les indicateurs pertinents et sensibles à l'état de fonctionnement de celui-ci. Ces indicateurs doivent être des paramètres invariants par rapport au mode de fonctionnement normal du système à surveiller. Ils permettent de construire un vecteur d'observation X_k du système sensible aux évolutions de la dynamique du système.

En considérant uniquement la partie conique du réservoir, le vecteur d'observation est donné par :

$$\begin{cases} X_k = [x_{k,1} & x_{k,2}], \\ x_{k,1} = h(k) - \left(\frac{3(Q_e - Q_s)}{\pi \tan^2(\theta)} k \right)^{1/3}, \\ x_{k,2} = h(k) - \frac{1}{2g} \left(\frac{Q_s}{s_i} \right)^2, \end{cases} \quad (4.3)$$

avec $s_i = \pi r_i^2$ la section de la vanne de vidange.

Après la construction du vecteur d'observation X_k , nous utilisons la technique *RdF* pour déterminer les modes de fonctionnement du système réservoir. La figure 4.5.a illustre le mode de fonctionnement du système obtenu par la technique de *RdF*. Pour modéliser la trajectoire de la vitesse des observations, nous considérons une fenêtre Ψ_Γ de taille $\Gamma = 8$, c'est-à-dire Ψ_8 contient 8 vecteur V_k . L'angle de seuil de détection $\alpha_d = 20^\circ$, la valeur de α_d est choisie par expérimentation. La matrice Ψ_Γ contient les vecteurs vitesse V_j consécutifs. Nous allons illustrer la technique de détection des dérives rapides en se basant sur la modélisation de la trajectoire des vitesses des observations issues du procédé. Les trajectoires des vitesses des observations,

lorsqu'il n'y a pas des dérivés rapides, sont représentées sur la figure 4.5.b. Sur la figure 4.5.b, nous remarquons que les angles entre des vecteurs consécutifs contenu dans Ψ_Γ sont tous ou presque supérieurs à α_i . Donc il n'y a pas de détection de dérive rapide sur le mode de fonctionnement représenté sur la figure 4.5.a.

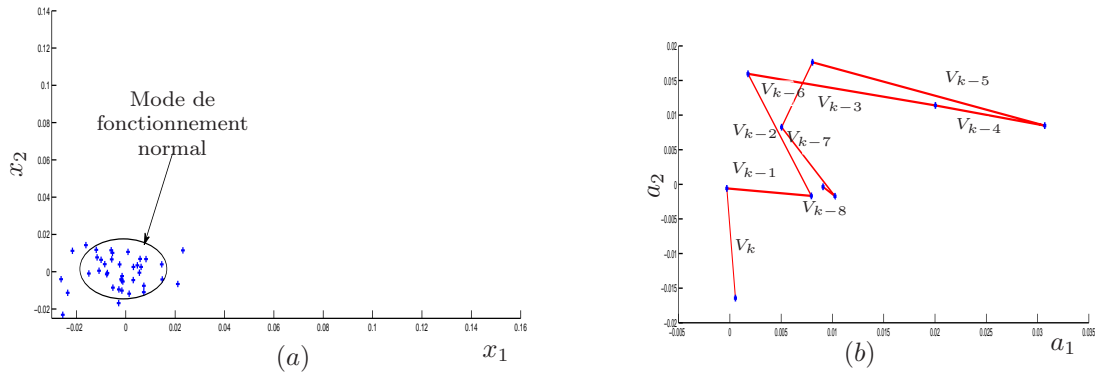


FIGURE 4.5 – Technique de détection des dérives rapides, (a) - mode de fonctionnement du système obtenu par la technique de *RdF*, (b) - trajectoire des vecteurs vitesses pour la détection des dérives rapides.

Dans le cas de la figure 4.6, un colmatage de la vanne de sortie est brutalement apparu. Les dérives rapides de fonctionnement qui correspondent à cette défaillance sont représentées sur la figure 4.6.a. Ces dérives rapides sont obtenues par une diminution successive de la valeur θ et s_i de la figure 4.4 comme montré sur le tableau suivant.

Instant(s)	41	42	43	44	45	46	47	48
$\theta(^{\circ})$	19.95°	19.90	19.85	19.80	19.75	19.70	19.65	19.60
$s_i(m^2)$	0.2	0.19	0.17	0.16	0.14	0.13	0.11	0.10

TABLE 4.3 – Évolution des paramètres θ et r_i ($s_i = \pi r_i^2$), voir annexe 1.

La figure 4.6.b montre que tous les vecteur V_j contenus dans Ψ_Γ s'orientent successivement dans le même sens que la dérive. Cela correspond à la détection d'une dérive rapide. Ainsi l'utilisateur du système est averti de cette dérive afin de prendre des précautions appropriées. Nous rappelons qu'une dérive est dite rapide si et seulement tout les angles entre deux vecteurs V_k consécutifs de la matrice Ψ_Γ sont inférieures au seuil de détection α_d (*cf* : chapitre 3).

L'un des avantages de cette technique de détection réside dans sa capacité d'être un outil de détection applicable en temps réel, car elle intègre la notion d'oubli des anciens vecteurs vitesses contenus dans la fenêtre Ψ_Γ . Mais cette technique nécessite un nombre suffisant de données avant de pouvoir être mise en œuvre.




FIGURE 4.6 – Détection des dérives rapides, (a) - dérives rapides de mode de fonctionnement du système, (b) - trajectoire des vecteurs vitesses.

4.4.3.2 Détection des dérives lentes

Les dérives lentes sont caractéristiques d'un encrassement ou d'un entartrage des composants du système au cours du temps. Elles se caractérisent par des évolutions lentes des classes correspondant aux modes de fonctionnement. Dans le chapitre 3, nous avons proposé une technique de détection de dérives lentes des classes exploitant les métriques entre les différents modes de fonctionnement connus *a priori*. La technique de détection des dérives lentes en fonction N_{fen} est donnée par la relation (3.5).

Les critères de détection de dérives lentes basés sur les taux de dérives sont présentés dans le chapitre 3 (*voir* tableau 3.5). Afin d'illustrer cette technique de détection, nous proposons de considérer uniquement l'encrassement du réchauffeur du système thermorégulateur. Les dérives lentes du réchauffeur sont illustrées à la figure 4.7. Pour obtenir l'encrassement du réchauffeur, nous avons fait tourner lentement et régulièrement la vanne située en aval du réchauffeur, sans endommager le composant.




FIGURE 4.7 – Encrassement du réchauffeur, avec C_n classe normale des 3 composants confondues, et C_{dr} , C_{de} et C_{df} respectivement les classes de défaillance du réchauffeur, de l'échangeur et du filtre.

La figure 4.8 illustre, les taux de dérives entre le mode normal du réchauffeur et les modes de

défaillance C_{d_r} , C_{d_e} et C_{d_f} . Nous observons sur la figure 4.8 qu'à l'instant $k = 750$, le taux de dérives T_{C_n, C_r} associé à la classe C_{d_r} tend vers -1 , tandis que les taux de dérives associés aux classes de défaillance C_{d_e} et C_{d_f} tendent vers 1. D'après les critères de détection de dérives lentes cités précédemment, l'évolution du taux $T_{C_n, C_{d_r}}$ vers -1 est due à l'encrassement du composant du réchauffeur.

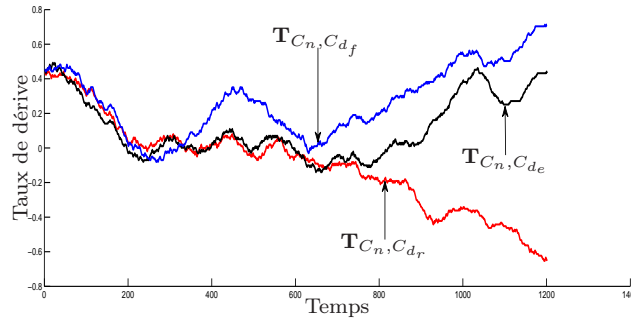


FIGURE 4.8 – Indicateurs des dérives lentes de fonctionnement basées sur les taux de dérives.

En fonction du sens d'évolution des taux de dérive, à chaque instant, les opérateurs ou les utilisateurs du système seront informés de l'état vers lequel évolue le système ou vers quel mode de défaillance le système dérive.

Les caractéristiques des modes de fonctionnement, c'est-à-dire les centres et les matrices de covariance, mises à jour en continu par *AUDyC* sont utilisées dans la section suivante pour déterminer en ligne les indicateurs de dégradation des différents composants du thermorégulateur soumis à des dérives lentes.

4.5 Indicateurs de dégradation des composants

Nous rappelons dans cette section que les trois composants du circuit chaud (réchauffeur, échangeur, filtre) du thermorégulateur sont soumis uniquement à des défaillances progressives qui se caractérisent par des évolutions lentes des modes de fonctionnement. Ces évolutions sont liées à l'encrassement des composants du thermorégulateur comme illustrées sur la figure 4.9.

Pour suivre l'encrassement des composants, nous avons proposé d'utiliser l'algorithme de classification *AUDyC*. Cet algorithme a pour objectif d'établir une représentation dynamique des différents modes de fonctionnement du procédé. Les caractéristiques des modes de fonctionnement déterminées en continu sont utilisées pour estimer les indicateurs de dégradation associés à chaque composant du thermorégulateur du côté circuit chaud.

Les indicateurs de dégradation définis par la relation (3.20) (*cf* chapitre 3) sont appliqués sur des données issues du système de thermorégulation présenté sur la figure 4.1. Pour obtenir les dérives lentes des composants du thermorégulateur illustrées sur la figure 4.9, nous avons fait tourner lentement et régulièrement la vanne relative à l'élément dont nous voulons simuler l'encrassement. Lorsque la vanne atteint l'arrêt de sécurité, elle est remise à la position initiale


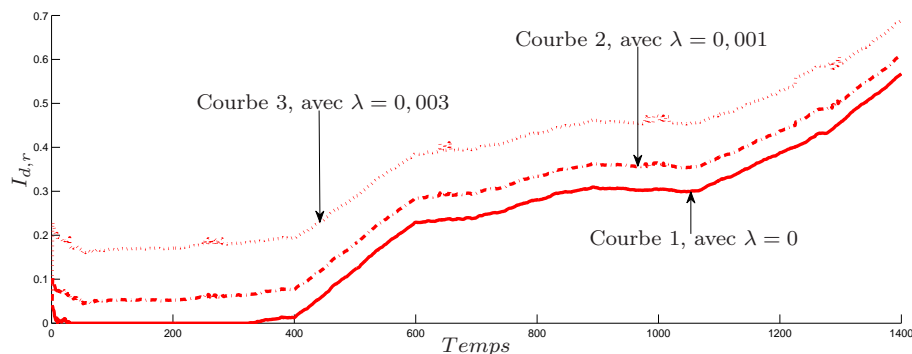


FIGURE 4.9 – Dérives lentes de fonctionnement des composants du thermostat.

(mode normal), et la simulation de dérives lentes sur le composant suivant peut commencer, c'est-à-dire les dérives ne sont pas simulées simultanément.

Pour montrer l'influence du choix de la valeur λ sur l'estimation de $I_{d,i}$, nous proposons d'étudier l'indicateur $I_{d,e}$ associés au réchauffeur avec différentes valeurs de λ . La figure 4.10 illustre l'indicateur de dégradation du réchauffeur avec des coefficients de pondération $\lambda = 0$, $\lambda = 0.001$ et $\lambda = 0.003$.

FIGURE 4.10 – Indicateurs de dégradation du réchauffeur avec différentes valeurs de λ ($\lambda = 0$, $\lambda = 0.001$ et $\lambda = 0.003$).

L'équation définie par la relation (3.20) dépend des centres et des traces des différentes classes correspondant aux modes de fonctionnements du système, donc permet de tenir compte de la géométrie et être lié au diamètre de la classe où a des considérations statistiques.

Le coefficient λ permet d'intégrer la variance des classes dans l'estimation de l'indicateur de dégradation $I_{d,e}$. Nous observons sur la figure 4.10 que si la valeur de λ est trop petit, la géométrie de la classe n'est pas pris en compte, ce qui conduit à ne considérer que l'indicateur basé sur la distance Euclidienne comme montre la courbe 1. Cependant, lorsque la valeur de λ est grande, la géométrie de la classe a une forte influence sur l'indicateur comme montre la courbe 3. Une

grande valeur de λ peut être source d'alarmes intempestives, qui imposeraient des interventions régulières des équipes de maintenance.

D'après la définition de la défaillance [60], les indicateurs de dégradation $I_{d,i}$ du circuit chaud peuvent être considérés comme les probabilités d'occurrence de défaillance de chaque composant i . Les techniques d'estimation des probabilités d'occurrence de défaillance du système thermorégulateur sont présentées dans la section suivante.

4.6 Estimation des probabilités d'occurrence de défaillance

A partir des résultats de l'AMDE fournis sur le tableau 4.1, un Arbre de Défaillance (*AdD*) du circuit chaud du système thermorégulateur est construit, comme illustré sur la figure 4.11. L'*AdD* est un outil pour les analyses de sécurité basé sur le calcul de probabilités d'occurrence de défaillance.

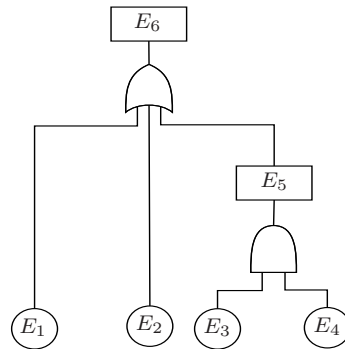


FIGURE 4.11 – Arbre de défaillance du thermorégulateur

Les événements de l'AdD sont :

- *Les événements de base* :
 - entartrage coté froid et chaud de l'échangeur $\rightarrow E_1$,
 - encrassement du réchauffeur $\rightarrow E_2$,
 - colmatage progressif des filtres $\rightarrow E_3$ et E_4 (en redondance passive).
- *L'événement intermédiaire* est :
 - colmatage d'un des filtres $\rightarrow E_5$
- *L'événement indésirable* est :
 - pas de régulation en température $\rightarrow E_6$

L'objectif est d'associer aux événements de l'*AdD* du système des probabilités d'occurrence de défaillance évoluant au cours du temps. Les probabilités des événements de l'arbre sont mises à jour de façon régulière de manière à ce qu'il soit possible de déterminer les risques de défaillances susceptibles d'apparaître. Ainsi, les probabilités estimées en ligne permettent de déterminer les conséquences les plus probables liées à leur occurrence et leur criticité (C) en continu. Pour temporiser et probabiliser l'*AdD* du système, nous proposons de considérer les indicateurs $I_{d,i}$

comme les probabilités d'occurrence de défaillance des événements élémentaires de l'arbre du système, notée $p^{E_i}(k) = I_{d,i}(k)$.

Les probabilités de l'événement intermédiaire E_5 et de l'événement indésirable E_6 de l'arbre sont obtenues par la propagation des probabilités des événements élémentaires. Les relations (4.4) et (4.5) sont utilisées pour calculer respectivement la probabilité d'occurrence des événements E_5 et E_6 à chaque instant k . Les événements E_1 , E_2 , E_3 et E_4 sont indépendants.

– Calcul de la probabilité en aval d'une porte "Et" :

$$p^{E_5}(k) = p^{E_4 \cap E_3}(k) = p^{E_4}(k) \cdot p^{E_3}(k), \quad (4.4)$$

– Calcul de la probabilité en aval d'une porte "OU" :

$$\begin{aligned} p^{E_6}(k) = p^{E_1 \cup E_2 \cup E_5}(k) &= p^{E_1}(k) + p^{E_2}(k) + p^{E_5}(k) - p^{E_1}(k) \cdot p^{E_2}(k) \\ &- p^{E_1}(k) \cdot p^{E_5}(k) - p^{E_2}(k) \cdot p^{E_5}(k) + p^{E_1}(k) \cdot p^{E_2}(k) \cdot p^{E_5}(k), \end{aligned} \quad (4.5)$$

Cette probabilité est basée sur le pourcentage de distance effectuée par le mode dégradé de chacun des composants en direction du mode défaillant qui lui est associé. Les probabilités p^{E_i} déterminées en temps réel sont utilisées pour calculer la criticité (C) de chaque événement de l'arbre de défaillance. La criticité est obtenue par le produit de la probabilité d'occurrence d'un événement et de sa gravité (criticité(C)=probabilité× gravité). Nous associons à chaque composant du système thermorégulateur, une gravité de "3", *i.e* une gravité forte, car l'indisponibilité de l'un des composants entraînerait l'arrêt du système.

Les probabilités p^{E_i} associées à chaque événement de l'arbre sont représentées sur la figure 4.12, avec la valeur de $p^{E_5} = p^{E_3}$, car $p^{E_4} = 1$ (*filtre₂* au repos). Ces probabilités p^{E_i} sont obtenues à partir du suivi en temps réel des dérives lentes des modes de fonctionnement de chaque composant du système (*voir* figure 4.9), en utilisant la relation (3.20). Les indicateurs de dégradation p^{E_i} sont utilisés par la suite pour pronostiquer l'état futur du système thermorégulation ou de ses composants.

Dans ce chapitre, nous nous appuyons sur la probabilité $p^{E_6}(k)$ du système thermorégulation pour prévoir son état futur sur un horizon de temps donné. La connaissance de la probabilité d'occurrence de défaillance future du système permet d'améliorer la prise de décision et la planifier des actions de maintenance prévisionnelle. La stratégie de pronostic de défaillance de systèmes dynamiques évolutifs est présenté dans la section suivante.

4.7 Pronostic de défaillance du thermorégulateur

En fonction des besoins et des contraintes de la maintenance, le pronostic de défaillance consiste à estimer la probabilité qu'une défaillance survienne sur un horizon de temps futur donné. La connaissance de l'état futur du système en continu permet de fournir des informations utiles pour maintenir le système tout en évitant l'arrêt non programmé du système et en augmentant conséquemment sa disponibilité et sa fiabilité. La figure 4.13 illustre notre architecture de




FIGURE 4.12 – Probabilité d’occurrence de défaillance avec $\lambda=0.001$, (a) - p^{E_1} du réchauffeur, (b) - p^{E_2} de l’échangeur, (c) - p^{E_3} du *filtre*₁, et (d) - p^{E_6} du système.

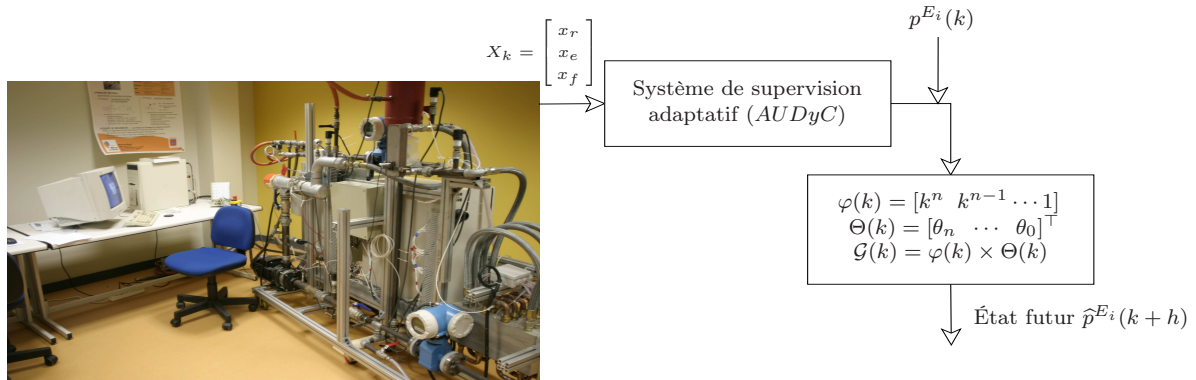


FIGURE 4.13 – Prédiction de l’état futur du système à partir de son état actuel.

pronostic de défaillance en ligne exploitant des probabilités d’occurrence de défaillance fournies par le processus de supervision.

Le pronostic de défaillance du thermorégulateur est réalisé en utilisant la deuxième approche de pronostic présentée dans le chapitre 3. Car les composants du thermorégulateur sont soumis à des dérives lentes. Cette approche consiste à modéliser la série temporelle $p^{E_i}(k)$ par un polynôme de degré n . Le polynôme modélisant la série temporelle $p^{E_i}(k)$ est donné par la relation suivante :

$$\begin{cases} \mathcal{G}(k+h) = \varphi(k) \Theta'(k), \\ \Theta'(k) = f(\Theta'(k-1), p^{E_i}(k), \varphi(k-h)). \end{cases} \quad (4.6)$$

Les coefficients $\Theta'(k)$ du polynôme \mathcal{G} sont mis à jour par la méthode des Moindres Carrés

Récurrents donnée par :

$$MCR : \begin{cases} K(k) = \frac{\mathcal{P}(k) \varphi(k-h)^\top}{1 + \varphi(k-h) \mathcal{P}(k) \varphi(k-h)^\top}, \\ \Theta(k) = \Theta(k-1) + K(k)(p^{E_i} - \varphi(k-h) \Theta(k-1)), \\ \mathcal{P}(k) = \mathcal{P}(k-1) - \frac{\mathcal{P}(k-1) \varphi(k-h)^\top \varphi(k-h) \mathcal{P}(k-1)}{1 + \varphi(k-h) \mathcal{P}(k-1) \varphi(k-h)^\top}, \end{cases} \quad (4.7)$$

avec $\varphi(k-h) = [(k-h)^n \ (k-h)^{n-1} \ \dots \ 1]$, $\mathcal{P}(k)$: mise à jour de la variance et $K(k)$: gain d'adaptation et h l'horizon de prédiction.

L'expression définie par la relation (4.8) est utilisée pour estimer la probabilité que la défaillance du système survienne sur un horizon de prédiction donnée. Ici, nous avons choisi de pronostiquer l'état futur du système, c'est à dire la série temporelle considérée est p^{E_6} (événement indésirable). La prédiction de l'état futur du système est réalisée sur différents horizons de prédiction avec différentes valeurs du degré du polynôme. La figure 4.14.(a) et (c) représente la p^{E_6} réelle (trait continu) et la p^{E_6} prédite (trait discontinu) sur un horizon de prédiction $h = 20$ et de différentes valeurs de n ($n = 2$ et $n = 8$), avec n le degré du polynôme. Ainsi, les erreurs de prédiction pour chaque valeur de n sont représentées sur la figure 4.14.(b) et (d). La relation (4.9) représente l'erreur entre la valeur réelle et la valeur prédite par le polynôme \mathcal{G} de degré n . L'approximation de la p^{E_6} , la prédiction de l'état futur et les erreurs de prédiction du système sur un horizon $h = 40$ sont représentées sur la figure 4.15.

$$\hat{p}^{E_i}(k+h) = \begin{cases} 0 & \text{si } \mathcal{G}(k+h) < 0, \\ 1 & \text{si } \mathcal{G}(k+h) \geq 1, \\ \mathcal{G}(k+h) = \varphi(k) \Theta'(k), & \text{sinon.} \end{cases} \quad (4.8)$$

$$\varepsilon^n = (\hat{p}^{E_i}(k+h) - p^{E_i}(k+h)). \quad (4.9)$$

Les figures 4.14.b et 4.14.d représentent les erreurs de prédiction en utilisant deux valeurs de n , ($n = 2$ et $n = 8$). Lorsque le degré du polynôme est grand, l'erreur de prédiction devient moins importante, mais le temps de calcul augmente. Cette erreur augmente également lorsque l'horizon de prédiction h est plus importante comme montré sur la figure 4.15.d.

La figure 4.16 montre que $n = 8$ est la valeur optimale. Cette valeur de n correspond au minimum de la somme normalisée des erreurs de modélisation de la tendance de dégradation.

4.8 Maintenance prévisionnelle du thermorégulateur

4.8.1 Stratégie de mise en œuvre de la maintenance prévisionnelle

La figure 4.17 représente l'architecture que proposons pour la mise en œuvre de la maintenance prévisionnelle du thermorégulateur basée sur les processus de supervision et de pronostic de défaillance en ligne.

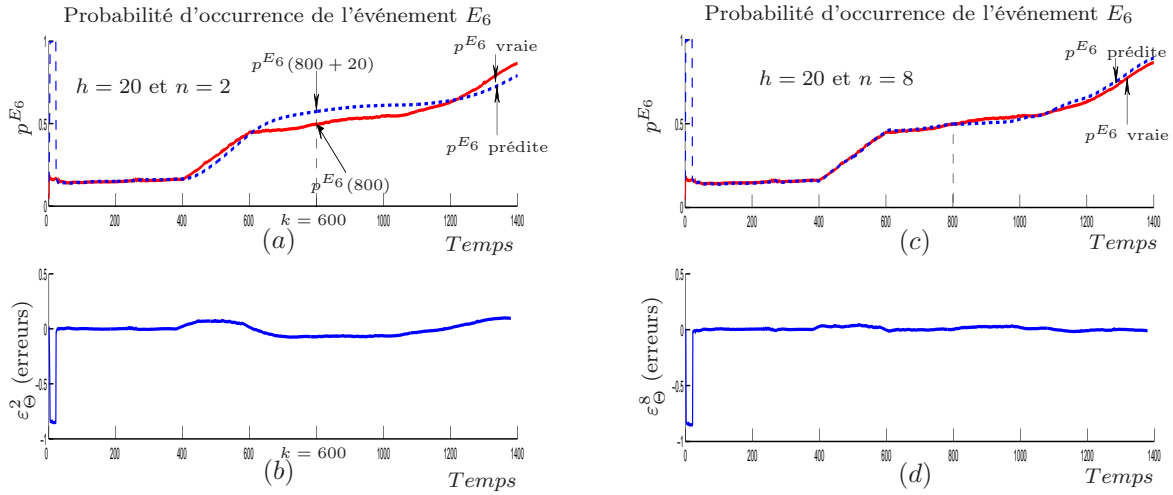


FIGURE 4.14 – Pronostic de défaillance, (a)&(c) - p^{E_6} avec différentes valeurs de n , et $h = 20$ et $\lambda = 0.001$ fixes, p^{E_6} réelle trait continu et p^{E_6} prédite trait discontinu, et (b)&(d) - erreur de prédiction.

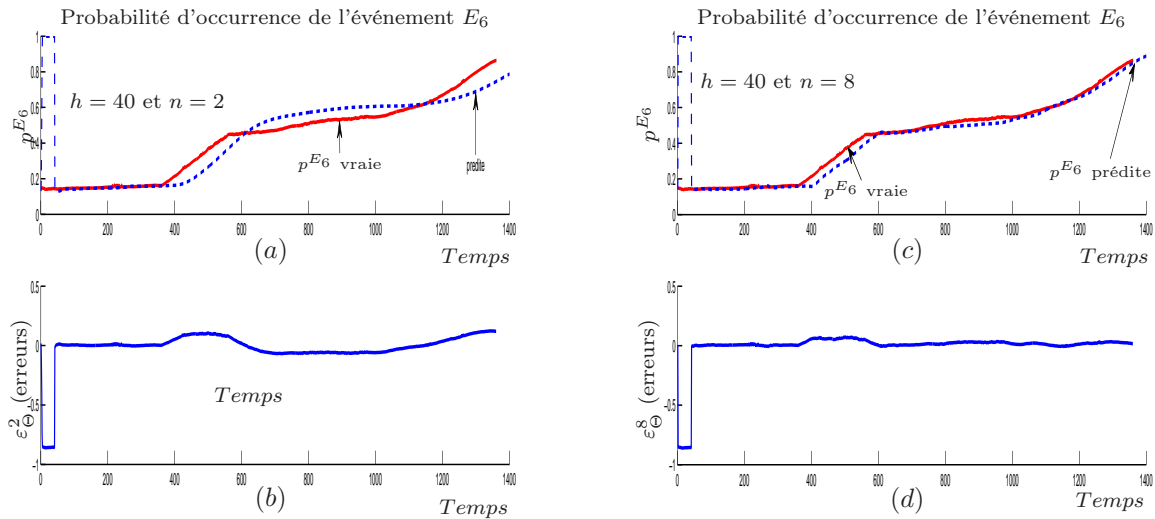


FIGURE 4.15 – Pronostic de défaillance, (a)&(c) - p^{E_6} avec différentes valeurs de n , et $h = 40$ et $\lambda = 0.001$ fixes, p^{E_6} réelle trait continu et p^{E_6} prédite trait discontinu, et (b)&(d) - erreur de prédiction.

Le réchauffeur, l'échangeur et le filtre sont soumis à des dérives lentes de fonctionnement liées à leur encrassement dû au fluide utilisé. Le suivi en continu de la dégradation de ces composants permet de prévoir la (les) défaillance(s) ou la détection à juste temps et la mise à jour de la criticité de l'analyse *AMDEC*. Le calcul de la probabilité d'occurrence de défaillance en ligne et la prédiction de l'état futur des composants sur un horizon de prédiction h permet d'obtenir respectivement un *AMDEC* à criticité évolutive et prédictive (voir tableau 4.4).

La criticité future a pour objectif de prévoir le risque futur de chaque composant du thermo-




FIGURE 4.16 – Choix du degré n du polynôme sur N observations.

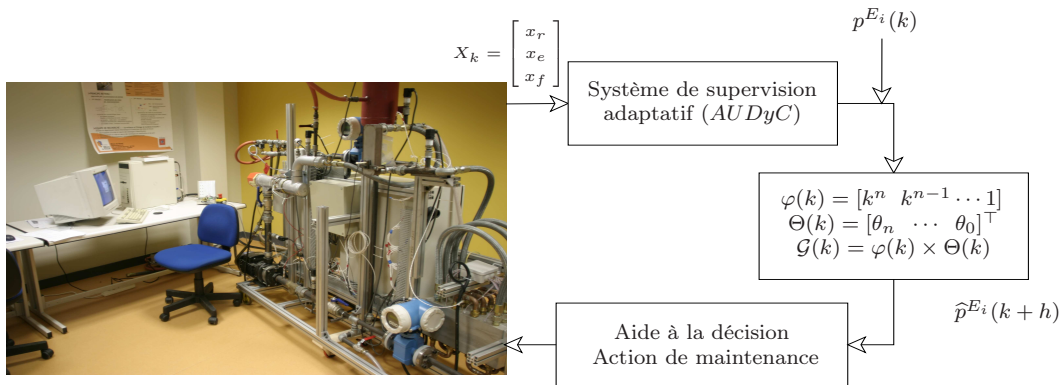


FIGURE 4.17 – Architecture de la maintenance prévisionnelle du thermorégulateur.

Composant	Modes de défaillance	Causes	Effets	Criticité	Criticité future
Échangeur de chaleur	Débit faible coté froid.	Entartrage (eau) coté froid et chaud.	Pas de refroidissement du fluide.	$p^{E_1}(k) \times g_1$	$p^{E_1}(k+h) \times g_1$
Réchauffeur électrique	Pertes des performances thermiques.	Encrassement	L'eau contenue dans le circuit chaud n'est pas chauffée.	$p^{E_2}(k) \times g_2$	$p^{E_2}(k+h) \times g_2$
Filtre	Colmatage	Colmatage progressif.	Pas de circulation d'eau.	$p^{E_3}(k) \times g_3$	$p^{E_3}(k+h) \times g_3$

TABLE 4.4 – L'AMDEC du thermorégulateur, avec une criticité déterminée un ligne et prédite.

régulateur en se référant à la matrice de criticité de risque définie à la figure 4.18⁹. En fonction de la zone de criticité future du composant ou du système dans la matrice et afin d'améliorer les performances du système, des actions de maintenance prévisionnelle peuvent être planifiées en fonction de la disponibilité des équipements de maintenance.

Pour synchroniser l'évolution des p^{E_i} des composants aux actions de maintenance, nous utilisons la conversion de l'Add de la figure 4.11 en Réseau de Petri (RdP) [99]. Le RdP du système est illustré à la figure 4.19.

Les composants du thermorégulateur sont soumis à des défaillances progressives. Cependant,

9. <http://www.in2p3.fr/actions/formation/OutilsProj08/DemarcheAnalyseRisques.pdf>

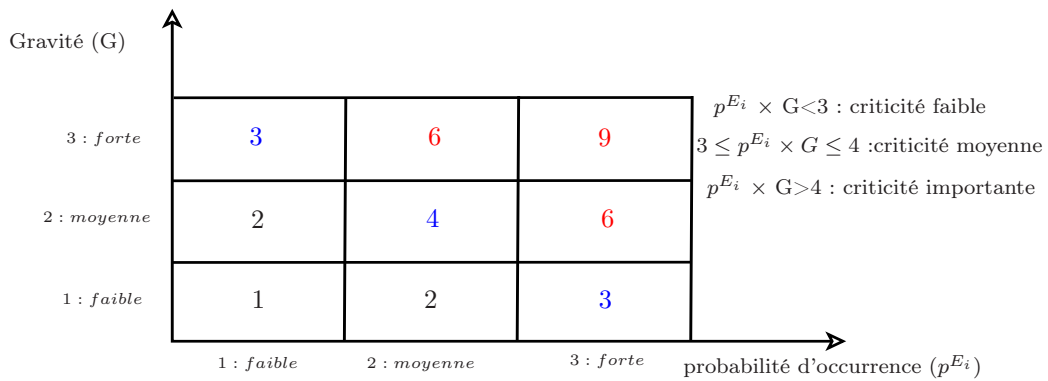


FIGURE 4.18 – Matrice de criticité des risques.

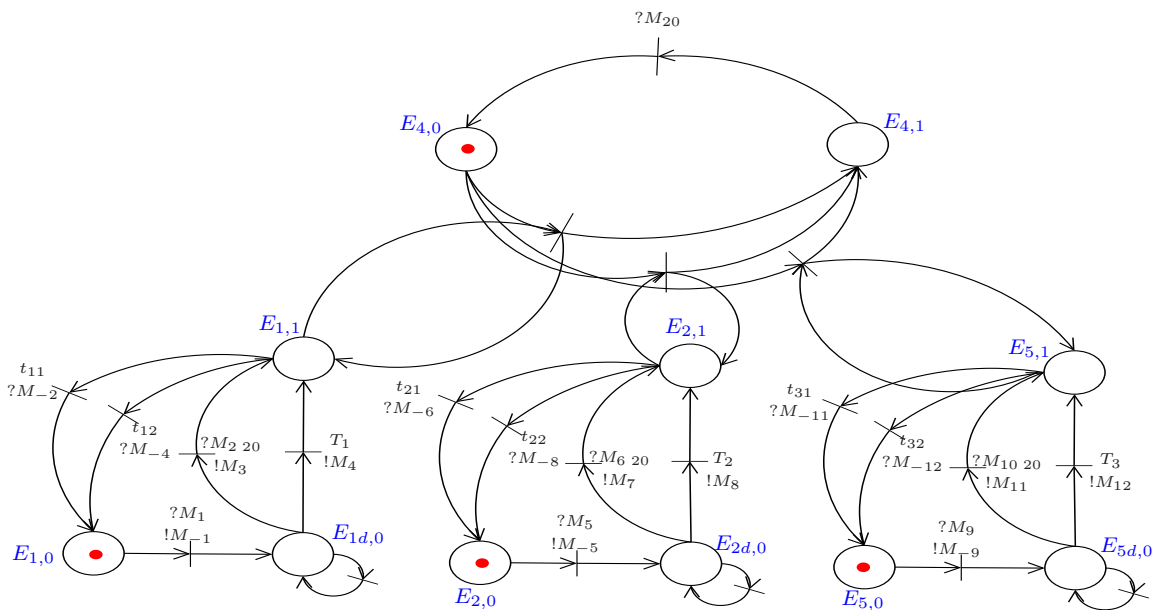


FIGURE 4.19 – Réseau de Petri correspondant au mode de fonctionnement du circuit chaud du thermorégulateur.

dans le *RdP*, chaque composant i est modélisé par trois places : mode de fonctionnement normal ($E_{i,0}$), mode de fonctionnement dégradé ($E_{id,0}$) et mode de fonctionnement défaillant ($E_{i,1}$). L'évolution des p^{E_i} des composants du système et la disponibilité des équipements de la maintenance sont synchronisées par des messages (voir figure 4.20). Les messages de synchronisation sont élaborés en fonction de l'évolution des probabilités d'échec. Ces messages de synchronisation sont représentés dans les tableaux 4.5, 4.6 et 4.7. Les messages associés à la disponibilité de l'équipement de maintenance sont présentés sur le tableau 4.8. Un message M_i est caractérisé par deux états : un état "Vrai" (M_i) et un état "Faux" (M_{-i}). Il peut être associé en entrée d'une transition, et participer à sa validation (message reçu). Dans ce cas, il est précédé du préfixe "?" (" $?M_i$ "). Un message M_j peut également être associé en sortie d'une transition (message émis). Dans ce cas, il est précédé du préfixe "!" (" $!M_j$ ") [98, 37, 90]. Lorsqu'une tran-

sition est tirée, le message qui lui est associé en sortie, peut être forcé dans l'état "Vrai" ou dans l'état "Faux". Une transition ne peut être sensible que si et seulement si le message qui lui est associé en entrée est vérifié et que le jeton est présent dans la (les) place(s) amont(s).

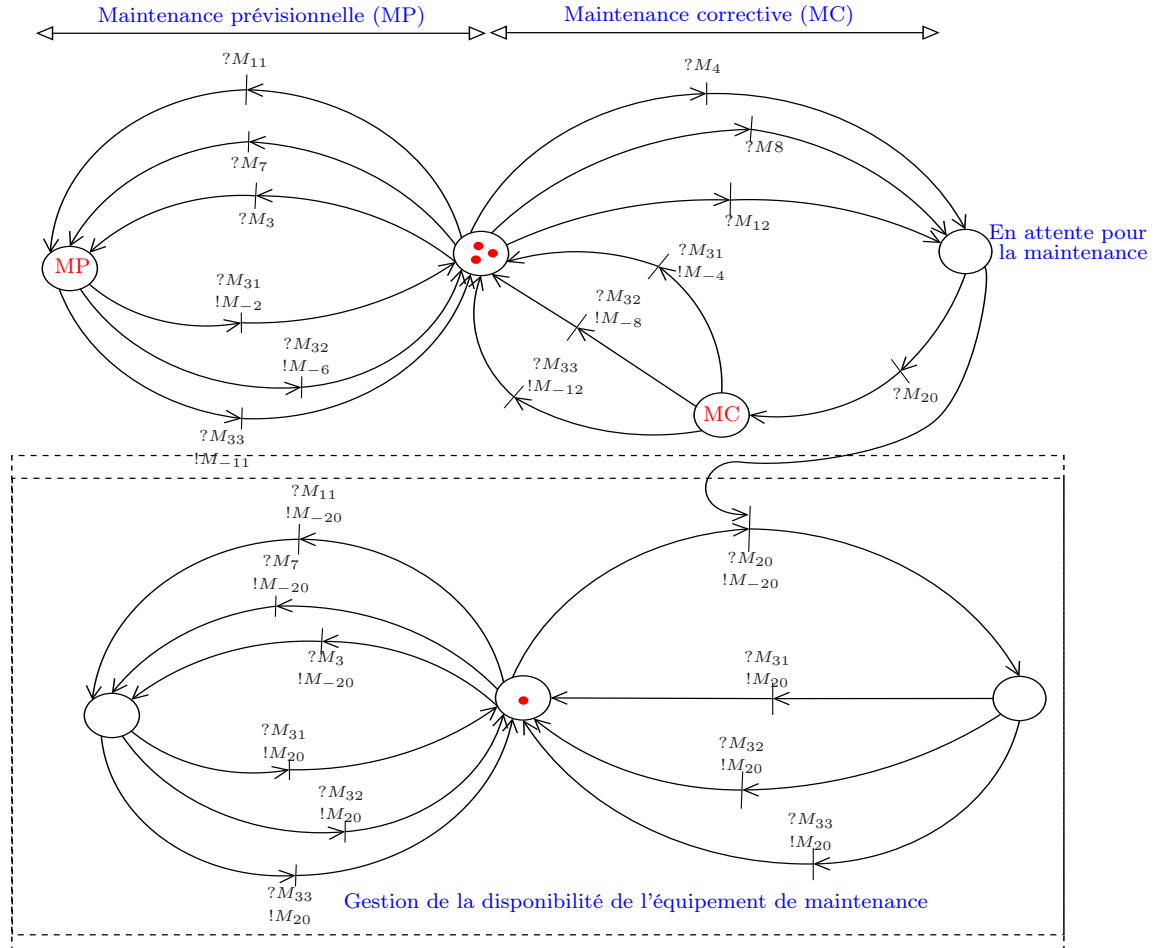


FIGURE 4.20 – Stratégie de maintenance du thermorégulateur.

Les messages de synchronisation entre les modèles de l'AdD et les modèles de maintenance en fonction de l'évolution de la probabilité d'occurrence de défaillance sont illustrés sur les tableaux suivants.

Message (booléen)	État du réchauffeur	Valeur initiale
M_1	Détection de l'évolution du mode de fonctionnement du réchauffeur.	Faux
M_2	La criticité du réchauffeur est dans la zone moyenne ou inacceptable de la matrice de criticité de risque.	Faux
M_3	Le réchauffeur est en cours de maintenance.	Faux
M_4	Le réchauffeur est dans le mode de fonctionnement défaillant.	Faux

TABLE 4.5 – Messages associés au mode de fonctionnement du réchauffeur.

Message (booléen)	État de l'échangeur	Valeur initiale
M_5	Détection de l'évolution du mode de fonctionnement de l'échangeur.	Faux
M_6	La criticité de l'échangeur est dans la zone moyenne ou inacceptable de la matrice de criticité de risque.	Faux
M_7	L'échangeur est en cours de maintenance.	Faux
M_8	L'échangeur est dans le mode de fonctionnement défaillant.	Faux

TABLE 4.6 – Messages associés au mode de fonctionnement de l'échangeur.

4.8.2 Planification d'actions de maintenance prévisionnelle

Le pronostic de défaillance du thermorégulateur est réalisé à partir de la 2^{ème} approche de pronostic présentée dans le chapitre 3, en modélisant p^{E_6} par un polynôme de degré $n = 8$. La relation (4.9) est minimale avec la valeur $n = 8$ pour un horizon de prédiction $h = 100$. Le choix de cette 2^{ème} approche est basé sur l'hypothèse qu'entre l'instant initial k_1 et $k_1 + h + 1$, le fonctionnement du système est assuré. Les coefficients des polynômes sont mis à jour par la méthode de Moindres Carrés Récursifs.

La figure 4.21.a représente la valeur de p^{E_6} du système et la figure 4.21.b illustre la prédiction de l'état futur du système, avec $h = 100$. La prédiction sur la valeur de p^{E_6} à l'instant $k = 1300$, montre que l'indisponibilité du système à l'instant futur $k + 100$ devient très probable d'après la tableau 4.9. Dans ce cas il sera nécessaire de trouver le composant qui a une forte probabilité p^{E_i} ou le composant qui se dégrade plus rapidement que les autres en exploitant la vitesse de dégradation. La figure 4.21.c montre qu'à partir de l'instant $k = 1200$ la probabilité d'occurrence de défaillance du filtre croît plus rapidement que les probabilités des autres composants.


Lorsque la probabilité du filtre est très élevée, le message M_{10} passe à l'état vrai comme

Message (booléen)	État du $filtrer_1$	Valeur initiale
M_9	Détection de l'évolution du mode de fonctionnement du $filtrer_1$.	Faux
M_{10}	La criticité du $filtrer_1$ est dans la zone moyenne ou inacceptable de la matrice de criticité de risque.	Faux
M_{11}	Le $filtrer_1$ est en cours de maintenance.	Faux
M_{12}	Le $filtrer_1$ est dans le mode de fonctionnement défaillant.	Faux

TABLE 4.7 – Messages associés au mode de fonctionnement du $filtrer_1$.

Message (booléen)	État du système	Valeur initiale
M_{20}	L'équipement de maintenance est prêt pour la maintenance.	Vrai
M_{31}	Fin de la maintenance du réchauffeur.	Faux
M_{32}	Fin de la maintenance de l'échangeur.	Faux
M_{33}	Fin de la maintenance du <i>filtre</i> ₁ .	Faux

TABLE 4.8 – Messages associés à la gestion de la disponibilité de l'équipement de maintenance.

FIGURE 4.21 – Probabilités, (a) - p^{E_6} du système, (b) - p^{E_6} du système prédite, (c) - p^{E_i} des composants du système et (d) - p^{E_6} du système avec action de maintenance, $\lambda = 0.001$.

illustré sur la figure 4.22, afin d'avertir à l'utilisateur de l'état de dégradation des composants du système. Le passage du message M_{10} à l'état vrai va permettre l'émission du message M_{11} à l'état vrai et le message M_{20} qui est déjà à l'état vrai passe à l'état faux. La synchronisation des *RdP* conduit à la planification d'une action de maintenance prévisionnelle pour le *filtre*₁. Ceci a pour effet de forcer la probabilité p^{E_3} du *filtre*₁ à 1 (arrêt). Le système va continuer à fonctionner en commutant sur le *filtre*₂, les deux filtres étant en redondance passive. La prédiction de l'état futur des autres composants du système permet également de savoir le temps nécessaire de maintenance sur chaque composant déjà déclaré critique. La commutation du système sur le *filtre*₂ a permis de réduire la probabilité d'occurrence de l'événement indésirable E_6 (voir figure 4.21.d).

Probabilités d'occurrence		
1	Faible	événement improbable $p^{E_i} \leq 5\%$
2	Moyenne	événement probable $5\% < p^{E_i} \leq 50\%$
3	Forte	événement très probable $p^{E_i} > 50\%$

TABLE 4.9 – Niveau d'acceptabilité des probabilités d'occurrence.




FIGURE 4.22 – État des messages de synchronisation.

4.9 Conclusion

La stratégie de maintenance prévisionnelle proposée dans ce chapitre est basée sur le couplage d'un arbre de défaillance élaboré à partir d'une analyse dysfonctionnelle de type *AMDE* (Analyse des Modes de Défaillance et de leurs Effets) et d'une architecture de supervision et de pronostic de défaillance. Cette architecture s'appuie sur un réseau de neurones à architecture évolutive *AUDyC* (AUto-adaptive and Dynamical Clustering) permettant une modélisation dynamique des modes de fonctionnement du procédé. Ce couplage a permis de déterminer les composants les plus critiques, leur mode de défaillance et le suivi en temps réel des caractéristiques des classes correspondantes aux modes de fonctionnement. Le couplage des deux approches a permis également d'estimer en continu, les probabilités d'occurrence de défaillance de chaque événement de l'arbre.

Les probabilités des événements de base sont déterminées en ligne et sont utilisées pour calculer la criticité de chaque composant du système. Ensuite, les probabilités p^{E_i} associées à chaque événement de l'arbre sont construites. Elles ont pour objectif de suivre de façon dynamique l'évolution des probabilités d'occurrence de défaillance des composants et du système, et de pouvoir déterminer leurs risques et leurs conséquences sur l'ensemble du système. Les probabilités p^{E_i} calculées en ligne sont aussi utilisées pour pronostiquer l'état futur du système. Une approche de pronostic basée sur la technique de régression des moindres carrés récursifs est illustrée sur un système réel. Cette technique s'appuie sur les probabilités réelles issues du système pour prédire son état futur sur un horizon de prédiction donnée. A partir de cette probabilité future, la criticité de chaque composant du système est évaluée. En fonction de la criticité future du système (risques

de défaillance), l'action de maintenance prévisionnelle est planifiée sur le composant défaillant ce qui a permis de réduire la probabilité d'occurrence de l'événement indésirable du thermorégulateur. La synchronisation entre l'évolution des probabilités d'occurrence de défaillance et la prise de décision pour planifier les actions de maintenance est rendue possible grâce à un réseau de Petri du système. Cet outil de modélisation pourrait s'avérer complexe dans le cas d'un système constitué de plusieurs composants, mais il joue un rôle très important pour la synchronisation entre les modèles de l'arbre de défaillance et les modèles de maintenance. Cette synchronisation est réalisée par des messages émis ou reçus par les transitions du réseau de Petri.

Conclusion générale et perspectives

Conclusion générale

Une complexité de plus en plus croissante et des contraintes d'exploitation de plus en plus sévères ont marqué la conception et l'exploitation des procédés industriels modernes. Ces évolutions contraignent les exploitants de ces procédés de se doter de systèmes de supervision et de pronostic performants pour les aider dans leurs activités de conduite et de maintenance, et ainsi leur garantir une plus grande maîtrise et une meilleure rentabilité. Dans ce contexte, la contribution de notre travail a consisté à proposer une approche générique pour la maintenance prévisionnelle de systèmes dynamiques évolutifs basée d'une part, sur des méthodes d'analyses de défaillance, plus particulièrement les techniques de l'Analyse des Modes de Défaillance, de leurs Effets et de leur Criticité (*AMDEC*) et de l'arbre de défaillance (*AdD*), et d'autre part, sur des techniques de supervision adaptative et de pronostic de défaillance. L'outil de supervision proposé est constitué d'un module de modélisation, d'un module de surveillance et d'un module de diagnostic. La modélisation du fonctionnement des procédés est réalisée par l'algorithme de classification dynamique de données évolutives *AUDyC* (AUto-adaptive and Dynamical Clustering) qui consiste à établir une représentation des différents modes de fonctionnement des systèmes évolutifs en continu. Cet algorithme de modélisation répond particulièrement bien à notre problématique puisqu'il possède la capacité de détecter des nouveautés et de créer de manière dynamique de nouveaux modes de fonctionnement. Les caractéristiques des modèles des modes existants sont adaptées au fur et à mesure que les données recueillies sur le procédé arrivent. Cette mise à jour en continu permet au système de surveillance de suivre en temps réel l'état de fonctionnement du procédé et de détecter tout changement de son comportement. En effet, la détection des changements de comportement de systèmes évolutifs est rendue possible grâce à la localisation des observations dans l'espace de décision et l'analyse de leurs trajectoires. A partir de techniques de régression modélisant la direction et la vitesse de la trajectoire des observations, ainsi que l'estimation des taux des dérives que nous avons proposées pour les dérives lentes de fonctionnement. Ces types de dérives sont particulièrement difficilement détectables, peuvent alors être détectées. Ces techniques conduisent à l'estimation en continu d'indicateurs de dégradation des systèmes évolutifs, qui sont définis, sous certaines hypothèses, comme des probabilités d'occurrence de défaillance des composants du procédé. Par la suite, les probabilités d'occurrence de défaillance sont utilisées pour temporiser et probabiliser les arbres de défaillance du système,

de façon à obtenir des *AdD* dont les probabilités d'occurrence des événements évoluent au cours du temps. Un modèle polynomial de la dégradation est ensuite utilisé par le processus de pronostic de défaillance afin de prédire la probabilité qu'une défaillance survienne sur un horizon de temps donné. Dans cette thèse, nous avons proposé deux approches de pronostic qui présentent l'avantage d'être facilement mises en œuvre et qui fournissent aux exploitants du procédé les probabilités d'occurrence de défaillance aux instants courant et futur de façon à améliorer la prise de décision et la planification des actions de maintenance. L'intérêt des outils proposés pour la mise en œuvre d'une stratégie de maintenance prévisionnelle de systèmes évolutifs est illustré sur des données issues d'un procédé réel de thermorégulation dans la dernière partie du manuscrit. La démarche permettant le déploiement des différents outils proposés est présentée sur ce système réel qui est soumis à des dérives lentes de fonctionnement. L'emploi d'outils tels que les *AdD* dynamiques et les Réseaux de Petri qui permettent la synchronisation des actions de maintenance a également été évalué et validé.

Perspectives

- La base de notre stratégie de maintenance prévisionnelle est l'*AUDyC*. Son utilisation requiert un choix d'un ensemble de seuils nécessaires à son fonctionnement optimal. Il serait intéressant de pouvoir réduire le nombre de paramètres à régler en proposant des critères automatiques de choix, par exemple la taille N_{fen} de la fenêtre glissante.
- Les indicateurs de dégradation que nous avons proposés sont basés sur la combinaison pondérée de la distance Euclidienne et la trace des matrices de covariance des différents modes connus. Il serait intéressant de proposer une méthode permettant le réglage automatique du coefficient de pondération λ en ligne. Par ailleurs, les approches de pronostic de défaillance proposées dans ce manuscrit sont basées sur une analyse de tendance. Une perspective intéressante serait d'aller au-delà du pronostic par analyse de tendance en développant un modèle dynamique boîte noire ayant comme composantes du vecteur d'état, certains paramètres des classes correspondant aux modes de fonctionnement évolutifs.
- Dans le chapitre 4, le couplage entre un *AdD* converti en *RdP* et l'outil de classification dynamique a permis de proposer une stratégie de maintenance prévisionnelle d'un système de thermorégulation. Cependant, la modélisation par *RdP* pourrait s'avérer complexe dans le cas d'un système constitué de plusieurs composants. Il sera nécessaire de proposer une méthode d'aide à la décision plus systématique que celle basée sur les connaissances pré-existantes permettant de sélectionner les composants essentiels au bon fonctionnement du système. Enfin, une autre perspective de travail consistera à enrichir, au cours du fonctionnement du procédé, le modèle conçu a priori en y intégrant des défaillances non envisagées initialement.

Bibliographie

- [1] AFNOR, *Maintenance - Concepts et définitions des activités de maintenance, Norme NF X 60-010, Association Française de Normalisation, 28 pages, 1994.*
- [2] B. Cart and V. Gosseaume and F. Kogut-Kubiak and M-H. Toutin. *La maintenance industrielle. Une fonction en évolution, des emplois en mutation. Centre d'Etudes et Recherche sur les Qualifications. Bref n°174, Avril 2001.*
- [3] I. Nikiforov. *Théorie de la décision et l'estimation. Cour Master2 optimisation et sûreté des systèmes. Université de Technologie de Troyes, 2007.*
- [4] ISO (2004). *Norme internationale ISO 13381-1 : Surveillance et diagnostic des machines-Pronostic. AFNOR, Paris.*
- [5] J. Aguiar-Martin and M. Balssa and R. Lopez de. *Estimation récursive d'une partition. Exemples d'apprentissage et auto-apprentissage dans R^n et I^n , LAAS-CNRS, Toulouse, France, Rapport scientifique No 880139, 7 p, 1980.*
- [6] J. Marzat. *Méthodologie pour la sécurisation en vol d'un aéronef sans ajout de capteur, ONERA, Toulouse, janvier 2010.*
- [7] N. Piera Carreté and P. Desroches and J. Aguiar-Martin. *LAMDA : An incremental conceptual clustering system. LAAS-CNRS, Toulouse, France. Rapport scientifique No 89420, 10 p, 1989.*
- [8] R. Adeline, R. Gouriveau, and N. Zerhouni. *Pronostic de défaillance : maîtrise de l'erreur de prédiction. MOSIM, Paris, France, 2008.*
- [9] H. Amadou-Boubacar. *Outils pour la détection de changement de comportement d'un système. Master's thesis, Université de Technologie de Lille, 2002.*
- [10] H. Amadou-Boubacar. *Classification dynamique de données non-stationnaires : apprentissage et suivi de classes évolutifs. PhD thesis, Université des Sciences et Technologies de Lille, 2006.*
- [11] J. Anguita and J. Hernando. *Inter-phone and inter-word distances for confusability prediction in speech recognition. Congreso de la Sociedad Española para el Procesamiento del Lenguaje Natural, (33) :pp. 33 – 40, 2004.*
- [12] S. Armand. *Analyse Quantifiée de la Marche : extraction de connaissances à partir de données pour l'aide à l'interprétation clinique de la marche digitigrade. PhD thesis, Université de Valenciennes et du Hainaut-Cambresis, 2005.*

- [13] L. Bako. *Contribution à l'identification de systèmes dynamiques hybrides*. PhD thesis, Université des Sciences et Technologie de Lille, 2008.
- [14] M. Basseville and I. Nikiforov. *Detection of abrupt changes. Theory and application*. Prentice Hall, 1993.
- [15] S. Bersimis, J. Panaretos, and S. Psarakis. Multivariate statistical process control charts and the problem of interpretation : A short overview and some applications in industry. *MPRA Paper 6397, University Library of Munich, Germany*, 2005.
- [16] S. Berthier. Surveillance et diagnostic d'un procédé thermique basés sur une modélisation de classes dynamiques. Master's thesis, Université de Technologie de Lille, 2004.
- [17] S. Bissol. *Indexation symbolique d'images : une approche basée sur l'apprentissage non supervisé de régularités*. PhD thesis, Université Joseph Fourier - Grenoble 1, 2005.
- [18] N. Boudaoud. *Conception d'un système de diagnostic adaptatif en ligne pour la surveillance des systèmes évolutifs*. PhD thesis, Université de Technologie de Compiègne, 1997.
- [19] M.S. Branicky, V.S. Borkar, and S.K. Mitter. A unified framework for hybrid control : Model and optimal control theory. *IEEE Trans. Automatic Control*, vol. 43(1) :pp. 31–45, 1998.
- [20] C. Byington, M. Roemer, M. Watson, T. Galie, and C. Savage. Prognostic Enhancements to Diagnostic Systems (PEDS) Applied to Shipboard Power Generation Systems. *Proceedings of ASME Turbo Expo. New York : ASME.*, 2004.
- [21] C. Byington, M. Watson, M. Roemer, and T. Galie. Prognostic enhancements to gas turbine diagnostic systems. *Proceedings of the IEEE Aerospace conference, Big Sky, USA*, 2003.
- [22] M.C. Carnero. Selection of diagnostic techniques and instrumentation in a predictive maintenance program. A case study. *Decision Support Systems*, vol. 38 :pp. 539 – 555, 2003.
- [23] R. Casimir. *Diagnostic des défauts des machines asynchrones par Reconnaissance de Formes*. PhD thesis, Ecole Centrale de Lyon, 2003.
- [24] R. Champagnat. *Supervision des systèmes discontinus : définition d'un système hybride et pilotage en temps-réel*. PhD thesis, Université Paul Sabatier de Toulouse, 1998.
- [25] J-N. Chatain. *Diagnostic par système expert*. Traité des nouvelles technologies. Série Diagnostic et maintenance, 1993.
- [26] V. I. N. Claudia. *Diagnostic par techniques d'apprentissage floues : conception d'une méthode de validation et d'optimisation des partitions*. PhD thesis, Université de Toulouse, 2007.
- [27] P. Cochetoux, A. Voisin, E. Levrat, and B. Iung. Formation du pronostic à base d'une approche processus. *PENTOM, Mons, Belgique*, 2007.

-
- [28] V. Cocquempot, R. Izadi-Zamanabadi, M. Staroswiecki, and M. Blanke. Residual generation for the ship benchmark using structural approach. *International Conference on control, Swansea (UK)*, pages pp. 1480 – 1485, 1998.
- [29] M. Combacau. *Commande et surveillance des systèmes à événements discrets complexes : application aux ateliers flexibles*. PhD thesis, Université Paul Sabatier de Toulouse, 1991.
- [30] M. Combacau, P. Berruet, P. Charbonnaud, and A. Khatab. Réflexion sur la terminologie "Surveillance - Supervision", Groupement de Recherche en Productique Systèmes de Production Sûrs de Fonctionnement SPSF, état des réflexions. 2000.
- [31] A. Debiolles. *Diagnostic de systèmes complexes à base de modèle interne, reconnaissance de formes et fusion d'informations. Application au diagnostic des circuits de voie ferroviaires*. PhD thesis, Université de Technologie de Compiègne, 2007.
- [32] E. Deloux. *Politique de maintenance conditionnelle pour un système à dégradation continue soumis à un environnement stressant*. PhD thesis, Université de Nantes, 2008.
- [33] M. Desinde. *Contribution à la mise au point d'une approche intégrée analyse diagnostique / analyse de risques*. PhD thesis, Université Joseph Fourier Grenoble 1, 2006.
- [34] O. E. Dragomir, R. Gouriveau, F. Dragomir, E. Minca, and N. Zerhouni. Review of prognostic problem in condition-based maintenance. *European Control Conference, Budapest, Hungary, 2009*.
- [35] B. Dubuisson. *Diagnostic et reconnaissance de formes*. Traité des nouvelles technologies, série Diagnostic et Maintenance, 1990.
- [36] B. Dubuisson. *Automatique et statistiques pour le diagnostic*. Hermes Science Publications, Paris, ISBN 2-7462-0248-4, 2001.
- [37] Y. Dutuit, E. Châtelet, J.P. Signoret, and P. Thomas. Dependability using stochastic modelling and evaluation by petri nets : application to two test cases. *Reliability Engineering and System Safety 55*, pages pp. 117 – 124, 1997.
- [38] M. El-Koujok, R. Gouriveau, and N. Zerhouni. Error estimation of a neuro-fuzzy predictor for prognostic purpose. *Safeprocess, Barcelona, Spain, 2009*.
- [39] P. M Frank. Fault diagnosis in dynamic systems using analytical and knowledge based redundancy - A survey and some new results,. *Automatica*, Vol. 26 :pp. 459 – 474, 1990.
- [40] M. C. Garcia, M. A. Sanz-Bobi, and J. del Pico. Intelligent System for Predictive Maintenance Application to the health condition monitoring of a windturbine gearbox. *Computers in Industry*, vol. 57 :pp. 552 – 568, 2006.
- [41] A. Girard. *Analyse Algorithmique des Systèmes Hybrides*. PhD thesis, Institut National Nolytechnique de Grenoble, 2004.
- [42] A. Giua and E. Usai. Modelling hybrid systems by high-level petri nets. *International Conference on the Automation of Mixed Processes N°3, Reims , France*, vol. 32 :pp. 1209 – 1231, 1998.

- [43] D. Guénet, M.-P. Moineau, J.-F. Morin, and J.-P. Codet. Exploitation des contrôles de qualité les cartes de levey-jennings sont-elles suffisantes en pratique quotidienne? *Immuno-analyse - Biologie spécialisée*, vol. 21 :pp. 172–180, 2006.
- [44] L. Hartert, M. S. Mouchaweh, and P. Billaudel. A dynamic classification method for the discrimination of evolving data. *International Fuzzy Systems Association World Congress, European Society for Fuzzy Logic and Technology. Lisbon, Portugal*, 2009.
- [45] P. Hore, L. O. Hall, and D. B. Goldgof. Single Pass Fuzzy C - Means. *FUZZ-IEEE*, 2007.
- [46] W. Jordan and G. Marshall. Failure modes, effects and criticality analysis. *in Annual Reliability and Maintainability Symposium, San Francisco, California*, 1972.
- [47] H. Kaffel. *La maintenance distribuée : conception, évaluation et mise en oeuvre*. PhD thesis, Université de Laval, 2001.
- [48] T. Kempowsky. *Surveillance de procédés à base de méthodes de classification : conception d'un outil d'aide pour la détection et le diagnostic des défaillances*. PhD thesis, Institut National des Sciences Appliquées de Toulouse, 2004.
- [49] S. Kullback and R. A. Leibler. On information and sufficiency. *Annal of Mathematical Statistics*, vol. 22 :pp. 79 – 86, 1951.
- [50] L. D. Landeau. *Identification des systèmes*. 1998.
- [51] M. Lebold and M. Thurston. Open standards for condition-based maintenance and prognostic systems. *5th Annual Maintenance and Reliability Conference (MARCON), Gatlinburg, USA*, 2001.
- [52] S. Lecoeuche and C. Lurette. Auto-adaptative and dynamical clustering neural network. *International Conference on Artificial Neural Networks, Istanbul , Turquie*, 2003.
- [53] S. Lepère. *Contribution à la prédiction en ligne des séries temporelles : un cas d'étude à la modélisation des systèmes dynamiques*. PhD thesis, Université de Technologie de Lille, 2001.
- [54] C.-J. Lin, C.-H. Chen, and C.-Y. Lee. A tsk-type quantum neural fuzzy network for temperature control. In *International Mathematical Forum, Taiwan*, 2006.
- [55] L. Ljung. *System identification. Theory for the user*. Practice Hall Information.
- [56] E. Diez lledo. *Diagnostic et pronostic de défaillances dans des composants d'un moteur d'avion*. PhD thesis, Université de Toulouse, 2008.
- [57] J. Luo, K. R. Pattipati, L. Qiao, and S. Chigusa. Model-based prognostic techniques applied to a suspension system. *IEEE Transactions on Systems, Man and Cybernetics*, 2006.
- [58] C. Lurette. *Développement d'une technique neuronale Auto-Adaptative pour la classification dynamique de données évolutives. Application à la supervision d'une presse hydraulique*. PhD thesis, Université des Sciences et Technologies de Lille, 2003.

-
- [59] C. Lurette and S. Lecoeuche. Unsupervised and auto-adaptive neural architecture for on-line monitoring : application to a hydraulic process. *Engineering Applications of Artificial Intelligence*, vol. 16 :pp. 441 – 451, 2003.
- [60] F. Ly. *Contribution par la surveillance prédictive indirecte à l'optimisation de la maintenance dans les systèmes flexibles de production manufacturière*. PhD thesis, Université des Sciences et Technologies de Lille, 1999.
- [61] M.H. Masson, B. Dubuisson, and C. Frélicot. Conception d'un module de reconnaissance des formes floues pour le diagnostic. *Journal Européen des Systèmes Automatisés, RAIRO-APII-JESA*, pages pp. 319 – 341, 1996.
- [62] K. Medjaher, A. Mechraoui, and N. Zerhouni. Diagnostic et pronostic de défaillances par réseaux bayésiens. *Journées Francophone sur les Réseaux Bayésiens, Lyon, France*, 2008.
- [63] Escobar L-A. Meeker, W-Q. Statistical methods for reliability data. wiley series in probability and statistics. john wiley & sons, inc. 1998.
- [64] G. Mercère, H. A. Boubacar, L. Bako, and S. Lecoeuche. Suivi de systèmes non-stationnaires basé sur une approche de reconnaissance de formes. *CIFA, Bordeaux, France*, 2006.
- [65] M. S. Moamar, P. Billaudel , and V. G. Lecolier. Following the evolution of a system using fuzzy pattern matching. *13th International Conference on Control Systems and Computer Science, Bucarest, Romania*, pages pp. 187 – 191, 2001.
- [66] S. B. Mohamed. Contribution à l'application de la reconnaissance des formes et la théorie des possibilités au diagnostic adaptatif et prédictif des systèmes dynamiques. Master's thesis, Université de Reims Champagne-Ardenne, 2007.
- [67] A. O. Molina. *Méthodologie pour le placement des capteurs à base de méthodes de classification en vue du diagnostic*. PhD thesis, Université de Toulouse, 2005.
- [68] M. S. Mouchaweh. *Conception d'un système de diagnostic adaptatif et prédictif basé sur la méthode Fuzzy Pattern Matching pour la surveillance en ligne des systèmes évolutifs. Application à la supervision et au diagnostic d'une ligne de peinture au trempé*. PhD thesis, Université de Reims-Champagne-Ardenne, 2002.
- [69] S.M. Mouchaweh, A. Devilles, G. V. Lecolier, and P. Billaudel. Incremental learning in fuzzy pattern matching. *Fuzzy Sets and Systems*, vol. 1 :pp. 49 – 62, 2002.
- [70] M. D. Mouss. *Diagnostic et conduite des systèmes de production par approche à base de connaissances*. PhD thesis, Université El-Hadj Lakhdar-Batna, 2005.
- [71] M.Traoré, E. Duviella, and S. Lecoeuche. Comparison of two prognosis methods based on neuro fuzzy inference system and clustering neural network. *Safeprocess, Barcelona, Spain*, 2009.
- [72] M.Traoré, E. Duviella, and S. Lecoeuche. Dynamical clustering technique to estimate the probability of the failure occurrence of process subjected to slow degradation. *ICINCO, Milan, Italy*, 2009.

- [73] M. Traoré, E. Duviella, and S. Lecoeuche. Pronostic de défaillance pour la maintenance d'un système de thermorégulation. *JD-JN-MACS, Angers, France*, 2009.
- [74] A. Muller. *Contribution à la maintenance prévisionnelle des systèmes de production par la formation d'un processus de pronostic*. PhD thesis, Université Henri Poincaré, 2005.
- [75] A. Muller, M-C. Suhner, and B Iung. Probabilistic vs. dynamique prognosis process-based e-maintenance system. *Information Control in Manufacturing, Salvador Brazil*, 2004.
- [76] R. Murray-Smith and T. A. Johansen. Multiple model. approches to modelling and control. *Taylor & Francis, London*, 1997.
- [77] S. Nascimento, B. Mirkin, and F. Moura-Pires. A fuzzy clustering model of data and fuzzy c-means. *IEEE International Conference on Fuzzy Systems*, vol. 1 :pp. 302 – 307, 2000.
- [78] Y. Nokoula. *Apprentissage des modèles linguistique flous, par jeu de règles pondérés*. PhD thesis, Université de Savoie, 1997.
- [79] H. Nomura, I. Hayashi, and N. Wakami. A learning method of fuzzy inference rules descent method. *in Proc. IEEE Int. Conf. Neural Networks, San Diego, USA*, pages pp. 203 – 210, 1992.
- [80] O. Ondel. *Diagnostic par Reconnaissance de Formes : Application à un ensemble convertisseur-machine asynchrone*. PhD thesis, Ecole Centrale de Lyon, 2006.
- [81] O. Ondel, E . Boutleux, and G. Clerc. A method to detect broken bars in induction machine using pattern recognition techniques. *IEEE Transactions on industry application*, vol. 42 :pp. 916 – 923, 2006.
- [82] O. Ondel, G. Clerc, E. Boutleux, and Eric Blanco. Fault detection and diagnosis in a set inverter-induction machine, through multidimensional membership function and pattern recognition. *IEEE Transactions on energy conversion*, vol. 24 :pp. 431 – 441, 2009.
- [83] R. Orjuela, B. Marx, J. Ragot, and D. Maquin. Une approche multimodèle pour le diagnostic des systèmes non linéaires. *3SGS, Nancy, France*, 2009.
- [84] E.S. Page. Continuous inspection schemes, *Biometrika*. vol. 41 :pp. 100 – 115, 1954.
- [85] M. A. Peltier and B. Dubuisson. A human operator monitoring process based on a fuzzy approach in tooldiag 93. *International conference on Fault Diagnosis*, 1993.
- [86] H. T. Pham, V. T. Tran, and B-S. Yang. A hybrid of nonlinear autoregressive model with exogenous input and autoregressive moving average model for long-term machine state forecasting. *Expert Systems with Applications*, vol. 37 :pp. 3310 – 3317, 2010.
- [87] P. Ribot. *Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes*. PhD thesis, Université de Toulouse, 2009.
- [88] M. Roemer, C. Byington, and G. Kacprzynsky. An Overview of Selected Prognostic Technologies with Reference to an Integrated PHM Architecture. *Proceedings of the First International Forum on Integrated System Health Engineering and Management in Aerospace*, 2005.

-
- [89] I. B. Santiago, J-M Faure, and Y. Papadopoulos. Including systematic fault tree analysis. *Safeprocess, Beijing, China*, 2006.
- [90] R. Schoening, J-F. Aubry, T. Cambois, and T. Hutined. An aggregation method of Markov graphs for the reliability analysis of hybrid systems. *International Journal on Reliability Engineering and System Safety*, vol. 91(2) :pp. 137 – 148, 2006.
- [91] J. Schutz. *Contribution à l'optimisation des plans d'exploitation et de maintenance, selon une approche basée sur le pronostic : application au domaine naval*. PhD thesis, Université Paul Verlaine-METZ, 2009.
- [92] W. A. Shewhart. *Economic Control of Quality of Manufactured Product*. American Society for Quality Control, 1931.
- [93] J. Shing and R. Jang. Neuro-fuzzy modeling architecture, analyse and application. Master's thesis, Dep. of Electrical Engineering and Computer Science, University of California, Berkeley, 1992.
- [94] J. Shing and R. Jang. ANFIS : Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and cybernetic*, vol. 23 :pp. 665 – 685, 1993.
- [95] Z. Simeu-Abazi and Z. Bouredji. Monitoring and predictive maintenance : Modeling and analysis of fault latency. *Computers in Industry*, vol. 57 :pp. 504 – 515, 2006.
- [96] T. Yan T, T. Lee, and M. Koç. Predictive Algorithm for Machine Degradation Detection Using Logistic Regression. In : *Managing Innovative Manufacturing "e-Manufacturing and e-Business Intégration"(MIM), Milwaukee, USA*, 2002.
- [97] J-H. Thomas. Diagnostic d'un système non stationnaire à partir d'une approche de reconnaissance des formes floue : Application au diagnostic de cliquetis moteur. *Traitement du signal*, vol. 16 :pp. 203 – 216, 1999.
- [98] M. Traoré. Développement de modèles en dynamique probabiliste prenant en compte la maintenance des systèmes. Master's thesis, Université de Technologie de Troyes, 2006.
- [99] M. Traoré, E. Duviella, and S. Lecoeuche. Supervision et pronostic pour la maintenance prévisionnelle de systèmes évolutifs complexes. *MOSIM, Paris, France*, 2008.
- [100] L. Tromp. *Surveillance et diagnostic de systèmes industriels complexe : une approche hybride numérique/symbolique*. PhD thesis, Université de Rennes1, 2000.
- [101] O. E. Vasile. *Contribution au pronostic de défaillance par le réseau neuro-flou : maîtrise de l'erreur de prédiction*. PhD thesis, Université de Franche-Comté, 2008.
- [102] S. Verron. *Diagnostic et surveillance des processus complexes par réseaux bayésiens*. PhD thesis, Université d'Angers, 2007.
- [103] G. Videau, T. Raïssi, and A. Zolghadri. Guaranteed state estimation for nonlinear continuous-time systems based on qLPV transformations. *European Control Conference, Budapest, Hungary*, 2009.

- [104] X. Wang, G. Yu, M. Koç, and J. Lee. Wavelet neural network for machining performance assessment and its implications to machinery prognostics. *In : Managing Innovative Manufacturing "e-Manufacturing and e-Business Intégration", Milwaukee, USA, 2002.*
- [105] J.E. Wieringa. *Statistical process control for serial correlated Data*. PhD thesis, Rijksuniversiteit Groningen, 1999.
- [106] L. Zadeh. Fuzzy Sets. *Information and Control*, vol. 8 :pp. 338 – 353, 1965.
- [107] J. Zaytoon. *Collectif Système dynamique hybrides Collection*. Ic2 systèmes automatisés, 2001.
- [108] R. M. Zemouri. *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance*. PhD thesis, Université de Franche-Comté, 2003.

Résumé de la thèse :

Une maintenance prévisionnelle efficace repose d'une part sur une modélisation précise de connaissances expertes préexistantes (*AMDEC*, Arbre de défaillance, etc.) et d'autre part sur des outils de supervision et de pronostic sensibles aux évolutions du procédé. La performance de ces outils repose sur l'analyse et l'estimation en temps réel de l'état du procédé, mais également sur la prévision de ses états futurs. Sur cette base, des indicateurs tels que les valeurs probabilistes issues du pronostic de défaillances peuvent être exploités pour la planification efficace d'actions de maintenance. En partant des connaissances expertes préétablies, nous proposons une approche de supervision adaptative basée sur une technique de reconnaissance des formes, *AUDyC* (AUto-adaptive and Dynamical Clustering), qui est particulièrement adapté aux systèmes dynamiques évolutifs et complexes. Cette approche permet de suivre en temps réel l'état de fonctionnement du procédé, avec un minimum de connaissances a priori sur ses caractéristiques physiques, de détecter et de diagnostiquer tout changement de son comportement, même si le système évolue vers un état jusqu'alors inconnu et d'actualiser la base de connaissance par intégration de nouveautés. Une approche de pronostic de défaillance couplée au processus de supervision adaptative est alors proposée afin de fournir en temps réel, l'état futur d'un procédé tout en estimant la probabilité qu'une défaillance survienne à un instant futur ainsi que la fiabilité de ce pronostic. Cette architecture de supervision adaptative et de pronostic proposée est utilisée pour la maintenance prévisionnelle des composants d'un système réel de thermorégulation.

Mots clés : *outils de détection des dérives, reconnaissance des formes, diagnostic adaptatif, pronostic, maintenance prévisionnelle, données non-stationnaires.*

_-----

Thesis abstract :

An effective predictive maintenance relies on the one hand, on an accurate modeling of available expert knowledge (Failure Mode, Effects and Criticality Analysis, Fault Tree, etc) and on the other hand, on monitoring tools that are sensitive to changes in the process under consideration. The performance of the monitoring tools consists not only in their ability to estimate and analyze the process state in real-time, but also in their capability to predict the future states. On this basis, indicators derived from the probabilistic prediction of failure occurrences can be exploited for the efficient planning of maintenance actions. Based on the predefined expert knowledge, we propose an approach of supervision based on a pattern recognition technique, the AUDyC algorithm (Auto-adaptive and Dynamical Clustering), which is particularly suitable for dynamic and complex systems monitoring. The proposed supervision approach allows us to (i) monitor the operational status of the system in real-time, with a minimum prior physical knowledge, (ii) detect and diagnose any change in the system behavior, even if the system evolves to a previously unknown state, (iii) update the basis of knowledge about the system by integrating new features into it. In order to provide in real-time an estimate of the future state of the system, a prognosis technique is coupled with the above mentioned supervision unit. This makes it possible to compute, with a certain reliability, the probability that a failure occurs at a given future time. Finally, the whole architecture for both supervision and prognosis is applied for the predictive maintenance of a real thermoregulation system.

Key words : *tools of detecting of the drifts, pattern recognition, adaptive diagnosis, prognosis, predictive maintenance, non-stationary data.*

