Université Sidi Mohammed Ben Abdellah
Faculté des Sciences Dhar El Mahraz- Fès
Centre d'Etudes Doctorales
"Sciences et Technologies"

Formation Doctorale : STIC

Discipline : Physique

Spécialité : Génie électrique

Laboratoire : Electronique Signaux Systèmes et Informatique

THESE DE DOCTORAT

Présentée par

FADILI Yassine

Développement d'algorithmes intelligents pour la commande et la détection des défauts pour un système éolien

Soutenue le devant le jury composé de :

Pr. TISSIR El Houssaine	***Faculté des Sciences Dhar El Mahraz - Fès***	***Président***
Pr. BOUMHIDI Ismail	***Faculté des Sciences Dhar El Mahraz - Fès***	***Directeur de thèse***
Pr. EL OUGLI Abdelghani	***Ecole Nationale des Sciences Appliquées - Oujda***	***Rapporteur***
Pr. LAGRAT Ismail	***Ecole Nationale des Sciences Appliquées - Kénitra***	***Rapporteur***
Pr. KABBAJ Mohammed Nabil	***Faculté des Sciences Dhar El Mahraz - Fès***	***Rapporteur***
Pr. AARAB Abdellah	***Faculté des Sciences Dhar El Mahraz - Fès***	***Examinateur***
Pr. ALFIDI Mohammed	***Ecole Nationale des Sciences Appliquées - Fès***	***Examinateur***
Pr. BENBRAHIM Mohammed	***Faculté des Sciences Dhar El Mahraz - Fès***	***Examinateur***

Année universitaire : 2018-2019

THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE SIDI MOHAMMED BEN ABDELLAH

Délivré par :

Laboratoroire d'Électronique, Signaux, Systèmes et Informatique (LESSI)

Présentée et soutenue le *Date de défense (JJ/MM/AAAA)* **par :**

Yassine FADILI

Développement d'algorithmes intelligents pour la commande et la détection des défauts pour un système éolien

---

JURY

Premier MEMBRE	Professeur d'Université	Président du Jury
Second MEMBRE	Astronome Adjoint	Membre du Jury
Troisième MEMBRE	Chargé de Recherche	Membre du Jury
Quatrième MEMBRE	Chargé de Recherche	Membre du Jury
Cinquième MEMBRE	Chargé de Recherche	Membre du Jury

École doctorale et spécialité :

Génie Électrique

Unité de Recherche :

Laboratoire d'Électronique, Signaux, Systems et Informatique (LESSI)

Directeur de Thèse :

Pr. Ismail BOUMHIDI

Rapporteur :

Noms des rapporteurs (s'ils ne font pas partie des membres du jury)

À mon très cher père ;

À ma très chère mère ;

À mes frères et mes sœurs ;

À toute ma famille ;

À tous mes professeurs ;

À tous mes amis ;

À tous mes collègues ;

À tous mes camarades.

Remerciements

Ce travail présenté dans ce mémoire de thèse a été réalisé, au sein du Laboratoire d'Electronique Signaux Systèmes et Informatique (LESSI), de la Faculté des Sciences Dhar El Mahraz, Université Sidi Mohamed Ben Abdellah de Fès, sous la direction scientifique de Mr. **Ismail BOUMHIDI**, professeur à la Faculté des Sciences Dhar El Mahraz de Fès, à qui je témoigne toute ma gratitude pour son soutien scientifique, ses conseils instructifs, pour le temps qu'il m'a accordé, son attention et son énergie dans un cadre agréable de complicité et de respect durant toute la période de préparation de ce travail.

Je désire aussi remercier Mr. **El Houssaine TISSIR**, professeur à la Faculté des Sciences Dhar El Mahraz de me faire l'honneur de présider le jury de ma soutenance. J'adresse mes profonds remerciements à Mr. **Abdelghani EL OUGLI**, professeur à l'Ecole Nationale des Sciences Appliquées de Oujda, à Mr. **Ismail LAGRAT**, professeur à l'Ecole Nationale des Sciences Appliquées de Kénitra, et à Mr. **Mohammed Nabil KABBAJ**, professeur à La Faculté des Sciences Dhar El Mahraz de Fès, qui m'ont fait l'honneur d'être rapporteurs de ma thèse. Leurs commentaires et leurs questions m'ont notamment permis d'améliorer ce manuscrit. Mes remerciements vont aussi à l'égard de Mr. **Abdellah AARAB**, professeur à la Faculté des Sciences Dhar El Mahraz de Fès, à Mr. **Mohammed ALFIDI**, professeur à l'Ecole Nationale des Sciences Appliquées de Fès, et à Mr. **Mohammed BENBRAHIM**, professeur à la Faculté des Sciences Dhar El Mahraz de Fès, pour avoir accepté de participer à mon jury de thèse.

Mes remerciements les plus sincères s'adressent à Mr. **Jaouad BOUMHIDI**, professeur à la Faculté des Sciences Dhar El Mahraz de Fès, qui m'a initié aux algorithmes d'apprentissage intelligents, et qui m'a fait bénéficier de ses encouragements et de ses remarques pertinentes. Je tiens aussi à exprimer ma profonde sympathie à toutes les personnes qui composent le laboratoire LESSI. Je remercie particulièrement tous les doctorants avec qui j'ai partagé ces années de thèse.

Je tiens à remerciés tous les membres de ma famille (ma mère, mon père, mes frères, mes soeurs, mes cousins et mes oncles) et tous mes camarades pour leur soutien au cours de ces longues années d'études et sans lesquels je n'en serai pas là aujourd'hui.

Mes grands remerciements vont aussi à mon Dieu qui m'a donné la capacité d'achever ce travail de thèse, et qui m'a aidé à dépasser toutes les difficultés que j'ai rencontrées.

Résumé

Dans cette thèse nous proposons des nouvelles stratégies de détection et d'isolation de défauts et de commande tolérante aux défauts pour le système éolien. Habituellement, la présence des défauts permet de minimiser la qualité de la conversion et de perdre la quantité d'énergie électrique générée par le système éolien, ce qui réduit l'efficacité de la conversion, vu que les défauts repoussent l'éolienne de démarrer et fonctionner loin de son fonctionnement normal. En effet, le diagnostic de défaut et la commande tolérante aux pannes apparaît donc comme des nécessités lorsque les défauts se produisent, pour qu'ils soient détectés et diagnostiqués rapidement et pour que l'action corrective puisse reconfigurer le système de commande et puisse accommoder le changement, afin de bénéficier d'une stabilité, une fiabilité et une sécurité d'un système éolien. Généralement, les méthodes de diagnostic sont divisées en deux catégories, une basée sur le modèle et autre basée sur les données. La première catégorie de diagnostic est composée principalement de deux fonctions de base : la génération des résidus et l'évaluation des résidus pour pouvoir décider la présence ou l'absence de défaut, à cette étude deux techniques de diagnostic sont dédiées pour l'éolienne, la première est basée sur une architecture générale à un banc d'observateurs et un seuil adaptatif à base d'énergie, et la deuxième est basée sur un observateur multi-intégrales proportionnelles sous leur forme multimodèle Takagi-Sugeno. Outre pour la deuxième catégorie, le problème du diagnostic se transforme en un problème de classification, où le classificateur permet de séparer les données parmi lesquelles le système est défectueux ou non, à ce travail deux techniques de diagnostic sont proposées pour l'éolienne. Finalement, nous avons développé une nouvelle technique de commande tolérante aux pannes pour le système éolien basé sur le principe de commande à modèle de référence optimisé par l'algorithme d'optimisation par essaims particulaires "PSO", pour générer l'action corrective qui puisse reconfigurer le système de commande en présence de défauts. L'ensemble des résultats présentés ont été illustrés par un exemple de simulation sur la plate-forme de simulation "Matlab'" pour montrer l'efficacité des techniques proposées à faire face aux pannes et d'imposer le fonctionnement optimal de l'éolienne.

Mots clés : Diagnostic ; Commande tolérante aux pannes ; Système éolien ; Défauts capteurs ; Défauts actionneurs ; Défauts système ; Seuil adaptatif ; Observateur ; Multi intégrales proportionnelles ; Multimodèle ; Classificateur ; Commande par modèle de référence ; Algorithme d'optimisation par essaims particulaires "PSO".

Abstract

In this thesis we propose new strategies of Fault Detection and Isolation and Fault Tolerant Control for the wind turbine system. Usually, the presence of faults minimizes the conversion quality and the amount of electrical energy generated by the wind turbine system, and reduces the conversion efficiency, since the failures hinder the wind turbine away of its normal functioning. In fact, the Fault detection and isolation "FDI" and the Fault Tolerant Control "FTC" therefore appear as requirements when the faults occur, so that they are detected and diagnosed quickly and that the fault corrective action can reconfigure the control system and accommodate the change to provide the stability, the reliability and the security of wind turbine system. Usually, the diagnostic methods are divided into two categories, one based on the model and another based on the data. The first category of diagnosis consists mainly of two basic functions : the residues generation and the residues evaluation to be able to decide the presence or the absence of defect, to this study two techniques of diagnosis are dedicated to the wind turbine, the first one is based on a general architecture at an observer's bench and an adaptive threshold, and the second is based on a multi-proportional integral observer in their Takagi-Sugeno multi-model form. In addition to the second category, the problem of diagnosis is transformed into a classification problem, where the classifier makes it possible to separate the data among which the system is defective or not, to this work two diagnostic techniques are proposed for the wind turbine, a is based on an observer based support vector machine adapted by fuzzy logic and other based on a classifier built by the Waikato Environment for Knowledge Analysis "WEKA", this hybrid classifier is based on the Bayesian algorithm static and neural networks with back propagation type learning and decision trees too. Finally, we developed a new fault-tolerant control technique for the wind turbine system based on the reference model control principle optimized by the particle swarm optimization "PSO" algorithm, to generate the corrective action that can be reconfigured. the control system in the presence of faults. All the results presented were illustrated by an example of simulation on the simulation platform "Matlab" to show the effectiveness of the techniques proposed to deal with breakdowns and to impose the optimal operation of the wind turbine system.

Keywords : Fault Detection and Isolation ; Fault tolerant control ; Wind turbine system ; Adaptive threshold ; Observer ; Multi proportional integrals ; classifier ; Model Reference Adaptive Control ; Particle Swarm Optimization Algorithm "PSO".

Table des matières

Table des sigles et acronymes **xvii**

1 État de l'art **5**

1.1 Introduction 6

1.2 Motivation 7

1.3 Classification et modélisation des défauts 9

1.4 Le diagnostic des défauts 11

1.5 La commande tolérante aux défauts 16

1.6 Généralités : Méthodes / Algorithmes 19

1.7 Conclusion 39

2 Conversion de l'énergie éolienne : Principe et modélisation des turbines 41

2.1 Introduction 41

2.2 Principe de la conversion d'énergie éolienne 42

2.3 Régulation de la puissance d'une éolienne 47

2.4 Description du système éolien 52

2.5 Conclusion 59

3 Diagnostic du système éolien **61**

3.1 Introduction 61

3.2 Diagnostic du système éolien à base de modèle 62

3.3 Diagnostic du système éolien à base de données 99

3.4 Conclusion 117

4 Commande tolérante aux défauts pour le système éolien 119

4.1 Introduction 119

4.2 Commande tolérante aux défauts basée sur modèle de référence et l'optimisation par Essaims particulaires 'PSO' pour l'éolienne 120

4.3 Conclusion 136

Conclusion 139

Bibliographie 141

Table des figures

1.1 Procédure de détection et d'isolation des défauts. 7

1.2 Système muni d'un module de diagnostic et d'une commande tolérante aux défauts. 8

1.3 Les défauts actionneurs, capteurs et composants. 10

1.4 Différents types de défauts : défaut aprubt, intermittent, graduel. 10

1.5 Différentes méthodes de diagnostic. 11

1.6 Principe des méthodes de diagnostic avec modèles. 12

1.7 Principe des méthodes de diagnostic basé sur les données. 14

1.8 Structure de commande par modèle de référence. 18

1.9 Marge souple. 22

1.10 Exemple de projection. 24

2.1 Tube de courant autour d'une éolienne. 44

2.2 Coefficient de puissance pour différents types d'éoliennes. 47

2.3 Courbe typique d'une turbine éolienne. 49

2.4 Coupe transversale d'une nacelle d'éolienne. 52

2.5 Schéma des sous-modèles de système éolien. 53

2.6 La structure du modèle de système d'entraînement à deux masses. 55

2.7 Séquence du vitesse de vent proposée dans ce mémoire. 58

2.8 Réference du couple générateur $\tau_{g,r}(t)$. 59

2.9 Référence de l'angle de calage du pâle $\beta_r(t)$. 59

3.1 Structure principale de diagnostic à base d'observateur pour le système éolien. 62

3.2 Observateur DOS pour la détection des défauts pour le système éolien. . . 64

3.3 Puissance générée $P_{g,m}(t)$. 75

3.4 Détection et isolation de défaut 1. 76

3.5 Détection et isolation de défaut 2. 77

3.6 Détection et isolation de défaut 3. 78

3.7 Détection et isolation de défaut 4. 79

3.8 Détection et isolation de défaut 5 dans le rotor. 80

3.9 Détection et isolation de défaut 5 dans le génerateur. 81

3.10 Détection et isolation de défaut 6. 82

3.11 Détection et isolation de défaut 7. 83

3.12 Détection et isolation de défaut 8. 84

3.13 Pôles situés dans la région d'LMI $S(\alpha, r, \theta)$. 87

3.14 Bruit centré proposé $\omega(t)$. 93

3.15 Estimation d'angle de position de calage de la pâle 1 $\hat{\beta}_1$. 94

3.16 Estimation d'angle de position de calage de la pâle 2 $\hat{\beta}_2$. 95

3.17 Estimation d'angle de position de calage de la pâle 3 $\hat{\beta}_3$. 96

3.18 Estimation de vitesse du génerateur $\hat{\omega}_g$. 97

3.19 Estimation de vitesse du rotor $\hat{\omega}_r$. 97

3.20 Estimation de couple générateur $\hat{\tau}_g$. 98

3.21 Estimation de défaut actionneur f_a et capteur f_s. 98

3.22 Structure principale de diagnostic à base de données pour le système éolien. 99

3.23 Schéma global de stratégie du diagnostic de l'éolienne par le classifieur adaptatif proposé. 105

3.24 Détection et isolation de défauts 1 par le classifieur adaptatif proposé. . . . 109

3.25 Détection et isolation de défauts 2 par le classifieur adaptatif proposé. . . . 110

3.26 Détection et isolation de défauts 3 par le classifieur adaptatif proposé. . . . 111

3.27 Détection et isolation de défauts 4 par le classifieur adaptatif proposé. . . . 112

3.28 Détection et isolation de défauts 5 par le classifieur adaptatif proposé pour le rotor. 113

3.29 Détection et isolation de défauts 5 par le classifieur adaptatif proposé pour le génerateur. 115

3.30 Détection et isolation de défauts 6 par le classifieur adaptatif proposé. . . . 115

3.31 Détection et isolation de défauts 7 par le classifieur adaptatif proposé. . . . 116

3.32 Détection et isolation de défauts 8 par le classifieur adaptatif proposé. . . . 116

4.1 Structure globale du FTC proposée. 121

4.2 Commande tolérante aux défauts proposée pour le système de la pâle 1. . . 128

4.3 Commande tolérante aux défauts proposée pour le système de la pâle 2. . . 129

4.4 Commande tolérante aux défauts proposée pour le système de pâle 3. . . . 130

4.5 Commande tolérante aux défauts proposée pour le système générateur : Couple générateur désiré. 131

4.6 Commande tolérante aux défauts proposée pour le système d'entrainement : Couple générateur. 133

4.7 Commande tolérante aux défauts proposée pour le système d'entrainement : Couple rotor. 134

4.8 Puissance générée $P_{g,m}$. 135

Liste des tableaux

2.1 Les paramètres du modèle d'éolienne traitée dans ce mémoire. 57

3.1 Les différents scénarios de défaut considérés dans ce travail. 65

3.2 Table de signature des défauts. 74

3.3 Le vecteur d'état pour chaque modèle local. 85

3.4 Valeurs de m et M pour chaque défaut. 107

3.5 Règles floues pour Δw. 107

3.6 Règles floues pour Δb. 107

3.7 Résultats de détection et d'isolation des défauts par le classifieur adaptatif proposé. 114

3.8 Résultats de la classification des données d'éolienne. 114

4.1 Valeurs des paramètres du MRAC proposé optimisé en appliquant le PSO. 136

Table des sigles et acronymes

ACP	*Analyse en Composantes Principales*
AFTC	*Active Fault Tolerant Control*
AQT	*Analyse Qualitative de Tendance*
AMDI	*Agence Marocaine de Développement et des Investissements*
BF	*boucle fermée*
BPNN	*Back-Propagation Neural Network*
CART	*Classification and Regression Trees*
CI	*Confidence Index*
DFIG	*Doubly Fed Induction Generator*
DOS	*Dedicated Observer Scheme*
FDI	*Fault Detection and Isolation*
FDD	*Fault Detection and Diagnosis*
FTC	*Fault Tolerant Control*
HAWT	*Horizontal Axis Wind Turbine*
IA	*Intelligent Artificiel*
IMM	*Interacting Multiple Models*
GADA	*Générateur Asynchrone à rotor bobiné à Double Alimentation*
GAS	*Générateur Asynchrone à cage d'écureuil*
GSAP	*Générateur Synchrone à Aimants Permanents*
GSRB	*Générateur Synchrone à Rotor Bobiné*
LCOE	*Levelized Cost Of Energy*
LQG	*Linear Quadratic Gaussian*
LQR	*Linear Quadratic Regulator*
LMI	*Linear matricial inequality*
LPV	*Linéaires à Paramètres Variants*
LTI	*Linéaires Invariants dans le Temps*

MAP	*Maximum a Posteriori*
MCP	*Moindres Carrés Partiels*
MIMO	*Multi Input Multi Output*
MIT	*Massachusetts Institute of Technology*
MMST	*Multiple Model Switching and Tuning*
MRAC	*Model Reference Adaptive Control*
OEP	*Optimisation par Essaims Particulaires*
PDC	*Parallel Distributed Compensation*
PFTC	*Passive Fault Tolerant Control*
PID	*Proportional Integral Derivative*
PIM	*Pseudo-Inverse Method*
PMIO	*Proportional Multi-Integral Observer*
PMSG	*Permanent Magnet Synchronous Generator*
PSOA	*Particle Swarm Optimization Algorithm*
Rdf	*Reconnaissance des formes*
SCIG	*Squirrel Cage Induction Generator*
SED	*Systèmes à Evénements Discrets*
SG	*Synchronous Generator*
SI	*Similarity Indix*
SIMO	*Single Input Multi Output*
SM	*Sliding Mode*
S.T.C	*Self Tuning Control*
SVM	*Support Vectors Machines*
SVR	*Support Vector Machine - Regression*
TS	*Takagi-Sugeno*
VAWT	*Vertical Axis Wind Turbine*
WECS	*Wind Energy Conversion Systems*
WEKA	*Waikato Environment for Knowledge Analysis*

Introduction Générale

L'énergie éolienne devient de plus en plus une source d'énergie significative, elle est aujourd'hui l'énergie la plus accessible en termes de technologie et de coûts et prend une place très importante parmi toutes les énergies exploitables par l'homme. L'intégration des systèmes éoliens au sein des systèmes énergétiques du point de vue prix nécessite l'amélioration de leur efficacité, à savoir la réduction des coûts d'opération et de maintenance, ainsi que l'augmentation de la puissance du vent captée. Aujourd'hui, cette filière d'énergie connait un développement rapide sur les plans technique et économique. Cependant, les défauts ne sont pas pris en compte, et souvent un petit défaut peut avoir un grand impact sur l'évolution du système éolien. Avec la demande croissante de disponibilité, d'éfficacité, de qualité, de fiabilité et de sûreté, les approches de traitement et de prise en compte de défauts sont devenues une question cruciale. Ces approches sont également connues sous l'appellation des systèmes de détection et d'isolation des défauts (Fault Detection and Isolation "FDI") et des systèmes de commande tolérante aux défauts (Fault Tolerant Control "FTC"). Le but est de détecter et de traiter les défauts de telle manière que le système puisse fonctionner d'une façon acceptable afin d'éviter l'arrêt du système.

La disponibilité non permanente de cette énergie due à l'intermittence et l'état stochastique du vent constitue une des problématiques majeurs de cette filière ayant ainsi une répercution directe sur leur coût d'exploitation. Heureusement, le développement des aérogénérateurs et l'introduction des convertisseurs de puissance ont permis d'améliorer le rendement de cette forme d'énergie dans les sites ventés. La surveillance de ces processus demande alors un suivi rigoureux. Cette dernière doit être capable de détecter les défauts aussi bien capteurs que systèmes, de les localiser, et de les identifier pour décider des actions à entreprendre. Ces différentes étapes, qui constituent la base du diagnostic, doivent être exécutées aussi rapidement que possible avec le minimum d'erreurs.

La théorie de diagnostic de l'état d'un système physique permet d'identifier toute sorte de ses anomalies à partir de l'observation de ses symptômes apparents. L'objectif de diagnostic ne s'arrête pas ici mais comprend aussi la définition des remèdes à apporter et la prise de mesures adéquates pour réparer ce système ou pour le ramener à son mode de fonctionnement normal. Cela concerne donc les tâches de prévention, de maintenance et de dépannage du système indiqué. Le diagnostic est en effet, un processus comportant trois grandes fonctions : la détection, la localisation et la décision. Le temps est un facteur

décisif dans le choix du modèle d'un système, dynamique ou statique, dans la réaction face à la détection des anomalies, fugitives ou évolutives, le plus rapidement possible, de les isoler, d'en identifier les causes probables de façon à réduire leurs effets néfastes, et puis de proposer des opérations de traitement correctives, urgentes ou adaptées.

Les machines éoliennes nécessitent périodiquement et en temps réel certaines maintenances. En effet, elles sont sous des conditions d'environnement et de fonctionnement variables. Une télémaintenance proactive automatisée s'impose, cela permet d'assurer une durée de vie optimale. Cela est justifié par le fait que l'arrêt d'une installation éolienne pour effectuer des opérations de maintenance non prévues, entraine des coûts très importants. Cette perte d'exploitation devient préoccupante pour toute entreprise, sans oublier la détérioration rapide des pièces de ces machines. Celle-ci est due à l'évolution fatale ou destructive des défaillances non surveillées qui conduit à des dégâts considérables. Pour résoudre ces problèmes, on a visé des objectifs dans cette thèse. Leur réalisation constituera une solution globale et satisfaisante. Il s'agit d'étude, de simulation, de conception d'une architecture de diagnostic en temps réel des défauts d'éoliennes.

Dans ce contexte, il existe une abondante production concernant les méthodes de diagnostic de défaut sur les systèmes éoliens. Les recherches partent des méthodes analytiques jusqu'à l'intelligence artificielle en passant par la modélisation des systèmes. L'objectif de toutes les méthodes proposées tend généralement vers la conception de systèmes de surveillance plus performants.

L'idée principale du ce document s'articule autour de deux points :

- ✓ Développement d'une méthode de diagnostic permettant la surveillance du système éolien, en s'appuyant sur deux axes principales. Premièrement, les approches basant sur le modèle, dans ce contexte, un observateur est défini afin de générer les résidus pour pouvoir décider la présence ou l'absence de défaut dans l'éolienne. Deuxièmement, les approches basées sur les données, Dans ce contexte le problème du diagnostic se transforme en un problème de classification, le classificateur est défini afin de pouvoir classifier les données parmi lesquelles le système défectueux ou non.
- ✓ Synthèse d'une loi de commande capable de s'auto-réparer le système éolien, de type commande tolérante aux défauts basées sur le modèle de réference et optimisée par la méthode d'optimisation par essaims particulaires "PSO", a pour objectif d'assurer au moins la stabilité de système ou mieux le comportement nominal et d'accroître la sécurité et la disponibilité des outils de production même en présence de défaut.

Motivé par ces raisons et pour atteindre les objectifs tracés, nous avons prévu de focaliser notre intérêt, de point de vue méthodologique, sur la formulation de plusieurs problématiques. Leur résolution constitue mes contributions et la valeur ajoutée de cette thèse. Ce mémoire est donc structuré en quatre chapitres avec une conclusion. Le **premier chapitre**, présente les principales approches de diagnostic liées à la problématique de diagnostic et de modélisation que nous avons organisé selon la classification suivante : les méthodes de traitement de données et les méthodes à base de modèle. Ensuite les principales stratégies de commande tolérante aux défauts sont présentés. Il permet notamment de classer diverses méthodes en deux grandes catégories : les lois des commandes tolérantes aux défauts passifs d'une part, et actives d'autre part. Les avantages et les inconvénients de chacune de ces méthodes de diagnostic et de commande tolérante sont détaillés. Ensuite, nous présentons un rappel de quelques outils intelligents de classification et d'optimisation, tels que : la classification par les Machines à Vecteurs de support (SVM), la classification naïve bayésienne, la classification par réseaux de neurones artificiels, la classification par arbre de décision, la logique Floue et la méthode d'optimisation par essaims particulaires "PSO". Le **deuxième chapitre** est consacré au système éolien, d'abord un petit historique de ce type d'énergie et de ce système éolien, puis la modélisation d'éolienne et essentiellement d'éolienne à vitesse variable et à axe horizontal. Le **troisième chapitre** est orienté vers la comparaison des données de deux méthodes de détection de défauts dans l'éolienne qui sont le diagnostic à base de modèle et le diagnostic à base des données. L'objectif de la comparaison est de mettre en évidence les avantages et inconvénients de chaque méthode. le premier classe de diagnostic basé sur l'estimation d'état utilise le principe de banc d'estimateurs à entrée inconnue. La détection des défauts est basée sur les donnée, cela passe soit par un classificateur adaptatif, ou bien par un classificateur hybride. Les deux approches sont soumises aux mêmes conditions de fonctionnement du dispositif à diagnostiquer, c'est-à-dire aux mêmes données d'entrées issues des données de simulation. Le **quatrième chapitre**, un contrôleur adaptatif est proposé pour la commande tolérante aux défauts pour le système éolien, ce contrôleur peut contrôler efficacement toutes les parties du système éolien, même les défauts du processus qui sont très difficiles à traiter en présence de bruits. L'idée est de concevoir un contrôleur adaptatif dans lequel la performance souhaitée est exprimée en matière de modèle de référence sans défaut et sans bruit, ce qui donne la réponse souhaitée à l'exécution du processus en temps réel. Puis l'utilisation de la méthode d'optimisation par essaims particulaires qui permet au contrôleur proposé de converger vers son point optimal de fonctionnement a travers la minimisation d'une fonction objective basée sur l'erreur entre le modèle de réference et le système. Enfin, une **conclusion** dans laquelle on conclu ce mémoire de thèse en résumant les différentes étapes

des travaux de recherche effectués et en fournissant les principaux résultats obtenus avec leurs perspectives.

Chapitre 1

État de l'art

Sommaire

1.1 Introduction 6

1.2 Motivation 7

1.3 Classification et modélisation des défauts 9

1.3.1 Selon leurs types 9

1.3.2 Selon leurs caractéristiques temporelles 9

1.3.3 Selon leur influence 11

1.4 Le diagnostic des défauts 11

1.4.1 Les méthodes de diagnostic à base de modèles 12

1.4.2 Méthodes de diagnostic sans modèles 14

1.5 La commande tolérante aux défauts 16

1.5.1 Méthodes passives 16

1.5.2 Méthodes actives 17

1.6 Généralités : Méthodes / Algorithmes 19

1.6.1 Les Machines à Vecteurs de Support (SVM) pour la classification . . 19

1.6.2 Classification naïve bayésienne 26

1.6.3 Classification par réseaux de neurones 30

1.6.4 Classification par arbre de décision 32

1.6.5 La logique Floue 34

1.6.6 Méthode d'optimisation par essaims particulaires "PSO" 36

1.7 Conclusion 39

1.1 Introduction

Ce chapitre permet de présenter quelques rappels sur des concepts fondamentaux relatifs au diagnostic et aux commandes tolérantes aux défauts, et ainsi sur les outils et les algorithmes dans lesquels s'insère l'étude menée dans l'ensemble de ce document.

Tout d'abord, dans le premier volet, un état de l'art des différents types de défauts et de leurs influences sur le processus à diagnostiquer et leurs modélisations est présenté. Dans un autre volet, les différentes méthodes de diagnostic seront présentées, elles seront regroupées en deux grandes familles : les méthodes basé sur les modèles mathématiques et celles basé sur les données. Puisque la décision de choix d'une méthode de diagnostic dépend de plusieurs facteurs, nous avons donc traité chaque classe avec leurs détails pour avoir une connaissance approfondie de chaque classe, afin d'être capable de décider le bon choix à chaque situation de diagnostic.

Par la suite, nous avons présenté les principaux concepts de synthèse de commande tolérante aux défauts. La classification des méthodes résultantes, permet d'effectuer un état de l'art de l'ensemble des méthodes de commande tolérantes aux défauts afin de synthétiser des systèmes tolérants aux défauts. Dans cette partie, les différentes méthodes de commande tolérantes aux défauts seront généralement classées en deux grandes familles distinctes : une approche passive (Passive Fault Tolerant Control (PFTC)) et une approche active (Active Fault Tolérant Control (AFTC)).

Dans la dernière section de ce chapitre, nous présentons un rappel de quelques outils intelligents de classification et d'optimisation, tels que : la classification par les Machines à Vecteurs de Support (SVM), la classification naïve bayésienne, la classification par réseaux de neurones artificiels, la classification par arbre de décision, la logique floue et la méthode d'optimisation par essaims particulaires "PSO". On pourrait dire que ces outils ne sont pas nouveaux, mais sont apparus à partir des années 80. Leur développement se fait à travers les méthodes par lesquelles l'homme essaye de copier la nature et de reproduire le raisonnement et le comportement qui lui sont propres. Ces outils intelligents peuvent être intégrés dans cette thèse pour la classification ou l'optimisation ou bien l'adaptation des techniques de diagnostic ou bien de commande tolérante aux défauts.

1.2 Motivation

Une augmentation permanente de la complexité, de l'efficacité et de la fiabilité des systèmes industriels modernes nécessite un développement continu de la théorie et de la pratique du contrôle et du diagnostic des défauts (FDI) [**1**]-[**2**]. Une combinaison modérée de ces deux paradigmes est étudiée de manière approfondie sous le nom de tolérance aux défauts (FTC) [**3**]-[**4**]-[**5**]. Aujourd'hui, la recherche et les applications de FDI et de FTC vont au-delà des systèmes de conversion d'énergie renouvelable, des systèmes de réacteurs nucléaires, d'installations chimiques ou d'aéronefs critiques acceptés pour la sécurité, des véhicules autonomes, etc... . Ce fait a pour objectif d'éviter les arrêts de système, les pannes et même les catastrophes impliquant des morts humaines et des dégâts matériels et aussi pour améliorer leurs performances.

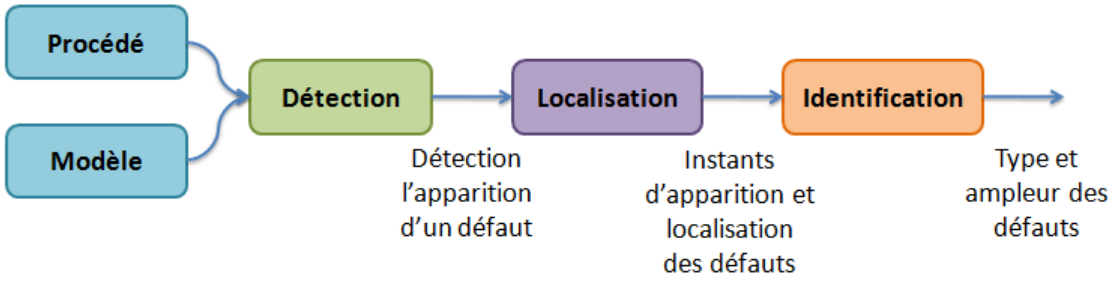


FIGURE 1.1 – Procédure de détection et d'isolation des défauts.

Le rôle du diagnostic des défauts est de surveiller le comportement du système et de fournir toutes les informations possibles concernant le fonctionnement anormal de ses composants. En conséquence, la tâche globale du diagnostic de panne comprend trois sous-tâches [**6**] (voir Figure 1.1) :

Détection de défaut : L'objectif de la procédure de détection est de déterminer l'apparition et l'instant d'occurrence d'un défaut. Le principe est de comparer le comportement du modèle nominal du système avec celui du système réel, c'est-à-dire déterminer si l'état de fonctionnement du système est normal ou anormal, ce qui permet de générer des résidus.

Localisation de défaut : Après avoir détecté la présence d'un défaut, une procédure de localisation est utilisée pour déterminer le composant ou l'élément défectueux. Cette opération porte le nom de localisation ou d'isolation de défauts. On parle de localisation quand on est, de plus, capable de préciser la nature du/des défaut(s) occurrent(s).

Identification du défaut : L'objectif de la procédure est d'identifier la valeur réelle du paramètre en défaut et d'estimer l'instant de l'apparition et l'instant d'occurrence d'un défaut.

Les connaissances résultantes de ces étapes sont ensuite transmises à la partie conception du contrôleur, qui est chargée de modifier la loi de commande de manière à maintenir les performances requises de système. Ainsi, le schéma présenté à la figure 1.2 peut être perçu comme tolérant aux défauts. Enfin, rien ne vaut que le terme symptôme dénote un écart d'une quantité observable par rapport au comportement normal.

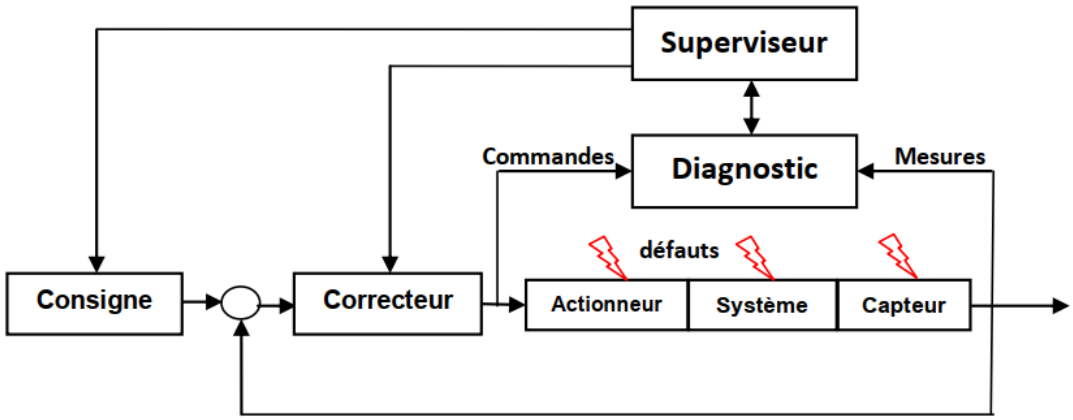


FIGURE 1.2 – Système muni d'un module de diagnostic et d'une commande tolérante aux défauts.

Une nomenclature variable a été établie au cours des années de développement des FDI et des FTC [**1**], qui peuvent être résumées comme suit :

La sécurité : La sécurité décrit l'absence de danger. Un système de sécurité fait partie de l'équipement de contrôle dans le seul but de protéger un système technologique contre les dommages permanents (ou d'éviter les pertes en vies humaines). Il permet un arrêt contrôlé, ce qui met le processus technologique dans un état sûr.

La fiabilité : La fiabilité est la probabilité qu'un système remplisse sa fonction pour une période spécifiée dans des conditions normales. Elle étudie la fréquence à laquelle le système est en panne, mais il n'est pas en mesure de fournir des informations sur l'état de défaillance actuel.

La disponibilité : La disponibilité est la probabilité qu'un système reste opérationnel

en cas de besoin. Contrairement à la fiabilité, elle dépend également des stratégies de maintenance, qui sont appliquées aux composants du système.

1.3 Classification et modélisation des défauts

Lorsque l'on conçoit un système de diagnostic, la première question que l'on se pose, est de savoir ce que l'on veut détecter, c'est-à-dire de définir le type de dysfonctionnement que l'on veut diagnostiquer. Pour ce fait on peut citer trois classes de défaut :

1.3.1 Selon leurs types

Généralement dans la littérature, les défauts sont des événements qui apparaissent à différents endroits du système (voir Figure 1.3). Donc, il est possible de distinguer trois types de défauts, à savoir :

Les défauts actionneurs : Un défaut actionneur est un dysfonctionnement représentant une perte totale ou partielle d'un actionneur agissant au niveau de la partie opérative et déteriorant le signal d'entrée du système.

Les défauts capteurs : Un défaut capteur peut aussi être partiel ou total. Ce défaut est la cause d'une mauvaise image de l'état physique du système. Un capteur totalement défectueux donne une information différente de la valeur réelle.

Les défauts systèmes : Les défauts systèmes sont des défauts qui apparaissent dans les composants du système lui même, c'est-à-dire les défauts qui ne peuvent pas être classifiés ni parmi les défauts capteurs, ni les défauts actionneurs. Ces défauts représentent des changements dans les paramètres du système. A cause de la diversité des situations de défauts, ce type de défaut est difficile à diagnostiquer.

1.3.2 Selon leurs caractéristiques temporelles

Une classification des défauts à partir de leurs évolutions temporelles peut être divisée en trois catégories distinctes (voir Figure 1.4) :

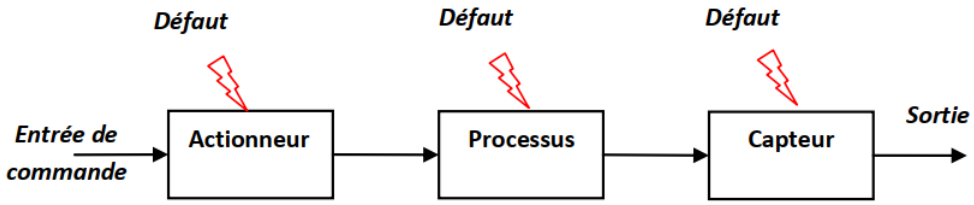


FIGURE 1.3 – Les défauts actionneurs, capteurs et composants.

Les biais (Abrupts) : Un biais se définit comme un saut brutal du signal. Habituellement, il est très grave car il affecte les performances et/ou la stabilité du système commandé. La caractéristique principale de ce type de défauts est la discontinuité dans l'évolution temporelle de la variable.

Les valeurs aberrantes (Intermittentes) : Les valeurs aberrantes sont des défauts dits fugitifs, qui représentent un cas particulier de défauts abrupts avec la propriété d'un signal qui revient de façon aléatoire aux valeurs normales. Ces défauts affectent le système de manière instantanée et se manifestent par un écart important par rapport à la valeur nominale du signal. Leur cause est souvent due à un parasite.

Les dérives (Graduels) : Une dérive correspond à une croissance lente et continue du signal défaut et donc un éloignement progressif de sa valeur nominale. Ce type de défaut est plus difficile à détecter à son origine du fait de sa faible amplitude et son évolution lente [**7**].

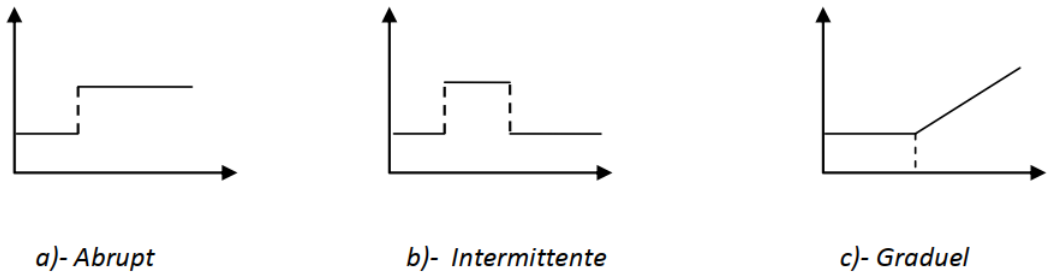


FIGURE 1.4 – Différents types de défauts : défaut aprubt, intermittent, graduel.

1.3.3 Selon leur influence

Les défauts peuvent être différenciés selon leurs influences sur les systèmes. Donc ils peuvent être qualifiés d'additifs et multiplicatifs. Les défauts sont additifs s'ils affectent le comportement du procédé indépendamment des entrées connues (tels que les défauts actionneurs et défauts capteurs). S'ils affectent le procédé d'une façon dépendante des entrées connues, ils sont considérés comme étant multiplicatifs (défauts système).

1.4 Le diagnostic des défauts

Nous nous intéressons dans cette étude à la définition technique, c'est-à-dire le diagnostic industriel. Alors le diagnostic est l'identification de la cause probable de (ou des) défaut(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test [**8**]. Cette définition résume deux tâches principales : observer les symptômes de la défaillance et identifier la cause à l'aide d'un raisonnement logique fondé sur des observations [**9**].

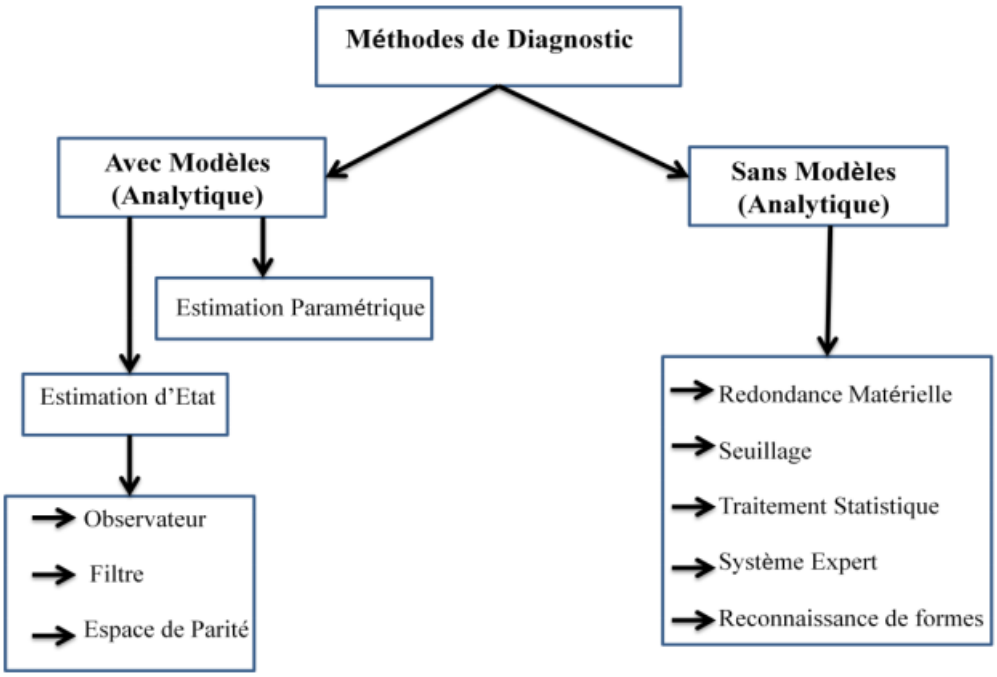


FIGURE 1.5 – Différentes méthodes de diagnostic.

Dans la plupart des cas, les méthodes de diagnostic sont liées à la connaissance disponible sur le procédé et à sa représentation et sont classées de différentes façons par de nombreux auteurs [**10**]-[**11**]-[**12**]-[**13**]. La terminologie et la classification ne sont pas toujours homogènes, influencées par les contextes et les terminologies particulières à chaque communauté et domaine d'application. Géneralement, il y a plusieurs méthodes de diagnostic connues et de nouvelles techniques sont proposées constamment dans la littérature, ces méthodes sont divisées en deux catégories (voir Figure 1.5) :

1.4.1 Les méthodes de diagnostic à base de modèles

Ces méthodes reposent sur une comparaison du comportement du système avec le comportement du modèle qualitatif et/ou quantitatif établi [**14**], tout écart est alors synonyme d'une défaillance (voir figure 1.6).

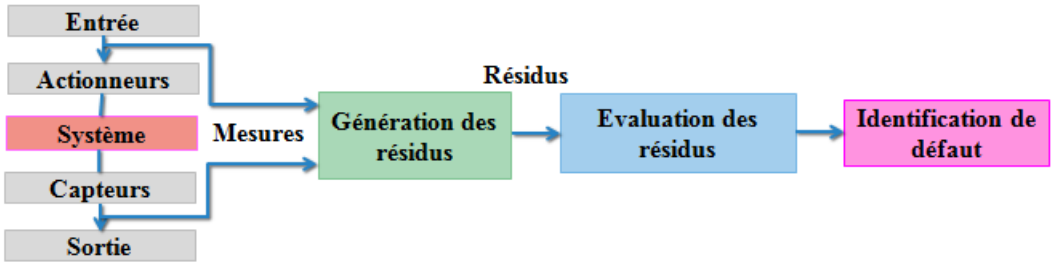


FIGURE 1.6 – Principe des méthodes de diagnostic avec modèles.

Selon le type du modèle (qualitatif et/ou quantitatif), on peut distinguer deux branches de méthodes : les méthodes quantitatives issues de la communauté FDI et les méthodes qualitatives issues des communautés IA et SED. La dissociation entre les méthodes qualitatives et les méthodes quantitatives n'implique pas que ces deux aspects sont disjoints. En réalité, ces deux types d'approche peuvent coexister au sein d'une même méthode de diagnostic.

1.4.1.1 Méthodes de diagnostic à base de modèles quantitatifs

Ces méthodes reposent sur l'estimation de l'état, des paramètres ou de l'espace de parité en utilisant des modèles mathématiques du système décrivant le comportement du système. Si l'écart entre ces modèles et les variables du système dépasse un certain seuil,

une défaillance est alors détectée. A ce moment, un résidu sera généré et comparé avec toutes les signatures des défauts connues, afin d'isoler et d'identifier la défaillance. Parmi les différentes méthodes de détection et de diagnostic utilisant des modèles mathématiques, nous trouvons principalement :

La méthode d'espace de parité : La méthode de l'espace de parité a été une des premières méthodes employées à des fins de FDI [**15**]-[**16**]. Cette méthode repose sur la vérification de la cohérence (parité) des modèles du procédé avec les mesures issues de capteurs et des entrées connues (consignes, signal de commande, etc...).

La méthode à base d'observateurs : Le principe de base de diagnostic par observateur consiste à estimer la sortie du système à partir des connaissances de la commande (ou partie de la commande), et des mesures (ou partie des mesures). Le vecteur résidu est ainsi construit comme l'écart entre la sortie estimée et la sortie mesurée [**17**]-[**18**]. Ces résidus doivent servir d'indicateurs fiables du comportement du processus.

La méthode d'estimation paramétrique : cette méthode suppose l'existence d'un modèle paramétrique décrivant le comportement du système et que les valeurs de ces paramètres en fonctionnement nominal soient connues. Elle consiste alors à identifier les paramètres caractérisant le fonctionnement réel, à partir de mesures des entrées et des sorties du système [**19**]. Pour détecter l'apparition de défaut dans le système, il faut effectuer la comparaison entre les paramètres estimés et les paramètres théoriques.

1.4.1.2 Méthodes de diagnostic à base de modèles qualitatifs

Les modèles qualitatifs permettent d'abstraire le comportement du procédé avec un certain degré d'abstraction à travers des modèles non plus mathématiques mais des modèles de type symbolique [**20**]. Ces modèles décrivent d'une manière qualitative l'espace d'état continu du système. Contrairement aux modèles de type numérique, les modèles qualitatifs ne représentent pas la physique du système, mais ils le décrivent en terme de mode de fonctionnement. Les méthodes à base de modèles qualitatifs peuvent être classifiées selon le niveau d'abstraction considéré du système à diagnostiquer, à savoir, les systèmes continus, les systèmes à événements discrets ou les systèmes hybrides dynamiques. Pour les systèmes continus, les approches ont été développées à base de graphes causaux [**21**] et de graphes causaux temporels [**22**]. Le diagnostic des SED est basé sur l'utilisation de modèles discrets tels que les réseaux de Petri et les automates d'états finis, etc... . Dans ce contexte, Sampath

et al. ont proposé dans [**23**] une approche de diagnostic devenue une référence dans la littérature. Cette approche consiste à modéliser le système par des automates à états finis, puis à construire son diagnostiqueur. Pour les systèmes hybrides, on trouve des méthodes reposant sur des modèles hybrides tels que les automates hybrides à temps discret [**24**], les bond graphs [**25**]-[**26**], les RdP hybrides [**27**], etc....

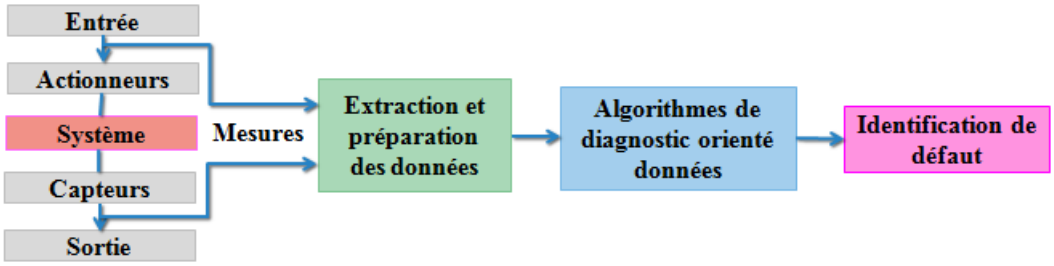


FIGURE 1.7 – Principe des méthodes de diagnostic basé sur les données.

1.4.2 Méthodes de diagnostic sans modèles

Dans certaines applications industrielles, il est difficile, voire impossible, d'obtenir le modèle du système. Cette difficulté est justifiée par la complexité accrue ou à de nombreuses reconfigurations intervenants durant le processus de production. En effet, seules les méthodes de surveillance sans modèles sont opérationnelles pour ce type d'applications industrielles. Ces méthodes de diagnostic se basent sur des informations issues d'une expérience préalable [**28**]-[**29**], sur des règles heuristiques ou encore sur des exemples de résolution, comme indiqué dans le schéma de la figure 1.7. Parmi ces méthodes, on trouve :

La méthode du seuillage : les signaux fournis par les capteurs sont comparées avec des valeurs limites constantes ou adaptatives (évoluant en fonction du point de fonctionnement) [**30**]. Un premier niveau indique la présence probable d'un défaut alors qu'un second niveau peut en caractériser la gravité. Le franchissement d'un seuil révèle la présence d'une anomalie.

Les méthodes statistiques : Les méthodes statistiques font partie des méthodes basées sur les données [**28**]-[**29**]. En étudiant les caractéristiques d'un ensemble d'objets ou d'observations, elles donnent un moyen essentiel pour la connaissance [**31**]-[**32**]. A partir de ces données, elles fournissent un outil graphique facilement manipulable et interprétable par l'opérateur. Malheureusement, cela demande la connaissance complète de la population,

ce qui rend ces méthodes coûteuses, voire impossibles dans certains cas (comme dans le cas des systèmes régis par des perturbations inconnues). La solution est donc d'utiliser les statistiques inférentielles qui consistent à utiliser la théorie de probabilités afin d'induire les caractéristiques inconnues d'une population à partir de certains échantillons tirés de cette population avec une certaine marge d'erreur, autrement dit la détermination d'une loi de probabilité à partir d'une série d'expériences.

Parmi les méthodes statistiques, on cite les Machines à Vecteurs de Support (SVM), classification par les réseaux de neurones intelligents, classification naïve bayésienne, Induction par arbre de décision etc.... . Tous ces méthodes ont été utilisées dans cette thèse à titre de diagnostiquer le système éolien. Dans la section de généralités, on propose donc de rappeler la théorie et les applications de chaque technique.

La reconnaissance des formes : ces méthodes reposent sur l'utilisation des algorithmes de classification des formes et des mesures (continues ou discrètes). Le fonctionnement d'un système de diagnostic par reconnaissance des formes se déroule en trois phases ([**33**]) :

- une phase d'analyse qui consiste à déterminer et à réduire l'espace de représentation des données et à définir l'espace de décision permettant de spécifier l'ensemble des classes possibles ;
- une phase de choix d'une méthode de décision permettant de définir une règle de décision qui a pour fonction de classer les nouvelles observations dans les différentes classes de l'ensemble d'apprentissage ;
- une phase d'exploitation qui détermine, en appliquant la règle de décision, le mode de fonctionnement du système en fonction de chaque nouvelle observation recueillie sur le processus.

Les systèmes experts : les systèmes experts utilisent une information heuristique pour lier les symptômes aux défauts [**34**]. Ce sont des systèmes à base de règles qui établissent des associations empiriques entre effets et causes [**35**]. Ces associations sont généralement fondées sur l'expérience de l'expert plutôt que sur une connaissance de la structure et/ou du comportement du système. Leur fonctionnalité est de trouver la cause de ce qui a été observé en parcourant les règles par un raisonnement inductif par chaînage avant ou arrière.

1.5 La commande tolérante aux défauts

Un système tolérant aux défauts possède la capacité de maintenir les objectifs nominaux en dépit de l'occurrence d'un défaut et à s'en accommoder de manière automatique. Il permet notamment de garantir la stabilité du système et/ou des performances dégradées acceptables en présence de défauts. Un conventionnel gain de retour d'état peut s'avérer très limité et amener le système vers des comportements non désirés, voire à l'instabilité, en présence d'un défaut. Pour pallier de telles catastrophes, de nouvelles lois de commande ont été développées dans le but précis de maintenir les performances du système ainsi que sa stabilité, lors d'un mauvais fonctionnement du système [**36**]. Dans le domaine industriel, ce type de problème a été souvent évité en se fondant sur la redondance matérielle à base d'actionneurs et de capteurs. Cette stratégie est non seulement onéreuse mais elle requiert aussi un important dispositif de maintenance. Ainsi, la commande tolérante aux défauts traitée de manière analytique, permet d'éviter de tels coûts d'achat et d'entretien.

La tâche principale qui incombe à la commande tolérante aux défauts est de synthétiser des lois de commande avec une structure permettant de garantir la stabilité et les performances du système, non seulement lorsque tous les composants de la commande sont opérationnels, mais aussi lorsque des capteurs ou des actionneurs sont défaillants.

La commande tolérante aux défauts est généralement classée en deux approches distinctes : une approche passive (Passive Fault Tolerant Control, PFTC) et une approche active (Active Fault Tolerant Control, AFTC).

1.5.1 Méthodes passives

Les méthodes PFTC utilisent les techniques de la commande robuste pour assurer que le système en boucle fermée demeure insensible à certains défauts avec des régulateurs constants et sans utilisation d'information en ligne des défauts sur le système [**37**]-[**38**]-[**39**]. Les régulateurs passifs ont pour but de maintenir le système "fiable" au sens de la stabilité et de ses performances dans les cas nominaux et de défauts prédéfinis. Le but est de chercher un régulateur qui optimise les performances "pour le pire défaut" (en terme de synthèse LQR ou H_∞) pour tous les défauts anticipés. Cette approche considère que les défaillances (défaut de 100%) peuvent apparaître dans un ensemble prédéfini de défauts potentiels sur les actionneurs et les capteurs. Le régulateur "passif" rejette le défaut si

ce dernier se modélise comme une simple incertitude. Pour une vue globale des méthodes des commandes robustes ou fiables, le lecteur pourra se référer aux travaux de [**40**]-[**41**]-[**42**]. En PFTC, le système en défaut continue d'opérer avec le même régulateur et la même structure du système : les objectifs et performances restent les mêmes que ceux du système nominal. Cependant, le système est synthétisé de manière à être robuste à certains défauts en supposant un ensemble de défauts potentiels restrictifs voire des fois un seul défaut. Ceci peut être valable dans certains cas restreints avec des défauts de faibles amplitudes. Dans des conditions pratiques, l'utilisation seule de la commande robuste peut être risquée. Comme un régulateur intelligent, sans utilisation de module de diagnostic et sans connaissance sur l'occurrence de défaut(sa sévérité, sa localisation,...), le système passif a alors une faible capacité de tolérance aux défauts.

1.5.2 Méthodes actives

Les méthodes AFTC se distinguent des méthodes PFTC par les principes énoncés précédemment tels l'utilisation d'un module FDD [**43**], une synthèse en ligne du régulateur, etc..., comme proposé par [**44**] et [**45**]. Il est possible de classer les AFTC selon certains critères tels que la commande active développée soit ou non :

- basée sur des lois de commande pré-calculées hors-ligne (méthodes de projection),
- basée sur de l'accommodation de défauts en ligne (commutation de modèles de défauts par exemple) et n'utilisant pas de FDI,
- tolérante aux défauts non-anticipés utilisant l'isolation et la détection des défauts.

Cependant certains types de commande active sont parfois difficiles à classer et de ce fait, l'explication ci-après n'est pas exhaustive mais permet de se repérer l'approche par modèle de référence qui nous intéresse dans ce mémoire.

Approche par modèle de référence : L'approche par modèle de référence est l'une des méthodes de commande active tolérante aux défauts qui permet la synthèse d'une nouvelle loi de commande telle que les performances du système défaillant commandé s'approche le plus possible de celles d'un modèle de référence, au sens d'un critère.

La commande adaptative par modèle de référence (MRAC) a été proposée pour la première fois en 1961 [**46**], il se basant sur la minimisation d'un indice de performance, approche connue généralement sous la règle de conception du MIT [**47**]. La structure en boucle fermée du MRAC est représentée par la figure 1.8. En effet, la différence entre la sortie du procédé et la sortie du modèle de référence est une mesure de la différence entre les

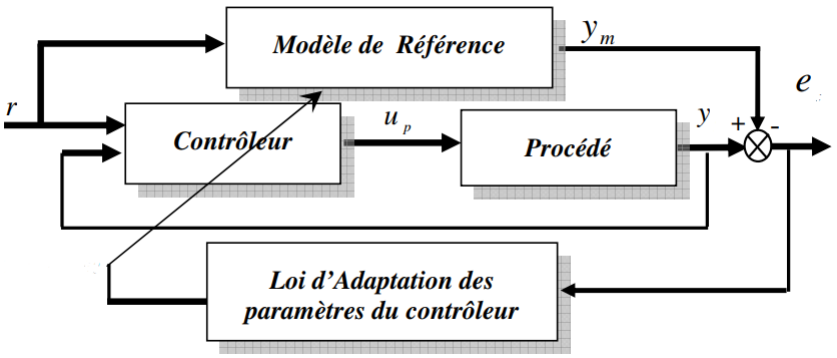


FIGURE 1.8 – Structure de commande par modèle de référence.

performances réelles et les performances désirées. Cette information est ensuite utilisée par le mécanisme d'adaptation pour ajuster les paramètres du régulateur afin de faire tendre l'erreur de comportement ou l'erreur de poursuite $e(t)$ vers zéro [**48**].

La règle du MIT a été élaborée pour la première fois en 1960 par des chercheurs du "Massachusetts Institute of Technology" (MIT) et utilisée pour concevoir le système de pilote automatique des aéronefs [**49**]. La règle MIT peut être utilisée pour concevoir un contrôleur avec un schéma MRAC pour n'importe quel système. Dans cette règle, la fonction de perte $J(\theta)$ est définie comme suit :

$$J(\theta) = \frac{1}{2}e^2(t) \tag{1.1}$$

Avec $e(t)$ est la différence entre la sortie du procédé $y(t)$ et la sortie du modèle de référence $y_m(t)$ comme indiquée dans la figure 1.8 :

$$e(t) = y(t) - y_m(t) \tag{1.2}$$

Et θ est le paramètre ajustable appelé paramètre de contrôle. Dans cette règle, le paramètre θ est ajusté pour que la fonction $J(\theta)$ peut être réduite à zéro. Pour cette raison, la variation du paramètre θ est maintenue dans la direction du gradient négatif de J, c'est-à-dire :

$$\frac{d\theta}{dt} = -\gamma\frac{\partial J}{\partial \theta} \tag{1.3}$$

À partir de l'équation (1.1), l'équation (1.3) devient :

$$\frac{d\theta}{dt} = -\gamma e\frac{\partial e}{\partial \theta} \tag{1.4}$$

Où, le terme de dérivé partiel $\frac{\partial e}{\partial \theta}$ est appelé dérivé de sensibilité du système. Ce terme indique l'évolution de l'erreur par rapport au paramètre θ.

L'équation (1.3) décrit l'évolution du paramètre θ par rapport au temps, de sorte que la fonction de fitnesse $J(\theta)$ puisse être réduite à zéro. Ici, γ est une quantité positive qui indique le gain d'adaptation du contrôleur.

1.6 Généralités : Méthodes / Algorithmes

1.6.1 Les Machines à Vecteurs de Support (SVM) pour la classification

La méthode des machines à vecteurs supports (SVM) fait partie des méthodes basées sur les données. Elle découle de la théorie d'apprentissage statistique. Elle est utilisée dans ce document pour la détection de défaut, et également pour la régression (modélisation).

La méthode des machines à vecteurs supports (SVM) est un nouvel estimateur non linéaire des fonctions, dont les fondements reposent sur la théorie statistique de l'apprentissage [**50**]-[**51**]-[**52**]. Le SVM est le classificateur le plus populaire, efficace et sophistiqué des algorithmes d'apprentissage automatique, cette technique introduit par Vapnik dans le début des années 1990 [**53**], son principe conçu pour trouver un séparateur optimal (représenté par les paramètres d'une fonction de décision) qui maximise la marge entre les frontières de chaque classe, par l'utilisation d'un ensemble limité d'entraînement. L'algorithme a été construit au début pour résoudre les problèmes de discrimination (classification) et de reconnaissance de formes. Il a été ensuite étendu pour le cas de régression.

Dans ce document, le terme SVMs est utilisé pour décrire à la fois la classification et la régression en utilisant les méthodes à vecteurs de support, le terme SVM sera utilisé pour décrire la classification par les machines à vecteurs de Supports tandis que le terme SVR sera utilisé pour décrire les méthodes de régression à vecteurs de supports.

Considérons le problème de séparation de l'ensemble D composé de N paires de données

/ classes d'apprentissage appartenant à deux classes (Ω_1, Ω_2) :

$$D = (x_1, z_1), \ldots, (x_i, z_i), \ldots, (x_N, z_N), \quad \Omega_1 = x_i | z_i = +1, \quad \Omega_2 = x_i | z_i = -1$$
$$i = 1 \ldots N, \quad x_i \in \Re^p, z_i \in +1, -1 \tag{1.5}$$

Où x_i indique l'entrée x_i (nommé aussi échantillon, observation, forme ou encore motif) est caractérisé par un ensemble de p variables descriptives. Et z_i indique la sortie définit la classe (ou l'étiquette, la cible ou encore la marque) du vecteur x_i.

L'objectif des SVMs est de trouver un hyperplan optimal $f(x)$ permettant de séparer les données d'apprentissage de sorte que tous les points d'une même classe soient du même côté de l'hyperplan. Donc, cet hyperplan d'un point de vue géométrique divise l'espace en deux. Ce type de problème présente en deux cas : cas des données linéairement séparables, et cas des données non linéairement séparables comme notre cas.

1.6.1.1 Cas de données linéairement séparables

La situation la plus simple lorsque les données sont linéairement séparables, il est clair qu'il existe une infinité d'hyperplans séparateurs permettant de séparer l'ensemble D en deux classes sans erreurs, mais la question qui se pose est comment trouver le meilleur séparateur. Dans le cas de séparation linéaire bien sur, l'hyperplan séparateur est défini par une fonction discriminante linéaire des exemples x, qui s'écrit sous la forme suivante :

$$f(x) = \langle w, x \rangle + b \tag{1.6}$$

w et b sont les paramètres de l'hyperplan séparateur, où w est le vecteur poids qui définit la direction perpendiculaire à l'hyperplan séparateur et b est le terme de biais (un scalaire). Ces paramètres sont calculés à partir des données formant l'ensemble D.

Cet hyperplan séparateur permet de mettre les points d'une même classe dans un même côté :

$$z_i(\langle w, x_i \rangle + b) \geq 1 \qquad pour \qquad i = 1, ..., N; \quad w \in \Re^p \quad et \quad b \in \Re. \tag{1.7}$$

Vapnik a montré qu'il existe une capacité optimale du classificateur qui est obtenue lorsque la distance entre l'hyperplan et les points les plus proches de chaque classe sera maximisée. Cette distance définie comme $\frac{1}{\|w\|}$ est appelée Marge. L'hyperplan optimal

sépare donc bien les deux classes de l'ensemble d'apprentissage, mais tout en minimisant la norme $\|w\|$. Par le choix de l'hyperplan qui maximise la marge, les SVMs minimisent le risque de surapprentissage. La minimisation de ce critère permet ainsi l'estimation des paramètres de l'hyperplan $f_w(x)$.

Le problème de minimisation est formulé comme un problème quadratique convexe sous sa forme primale par la minimisation de $\|w\|^2$ tout en respectant des contraintes linéaires :

$$\begin{cases} \min\left(\frac{1}{2}\|w^2\|\right) \\ \\ sous \quad les \quad contraintes \\ \\ z_i f(x_{i,}) \geq 1 \quad pour \quad i = 1, \ldots, N \end{cases} \tag{1.8}$$

Où $f(x_i) = \langle w, x_i \rangle + b$ est la sortie prédite.

1.6.1.2 Cas de données non linéairement séparables

Dans la plupart des problèmes réels, les données ne sont pas linéairement séparables à cause de la nature des systèmes généralement non linéaires et la présence de bruits dans ces données mesurées comme le cas de notre étude du système éolien. Pour surmonter ces difficultés, les SVMs ont été généralisés grâce à deux outils : la marge souple et les fonctions noyaux.

A. *Marge souple (ou marge douce)*

Pour permettre de résoudre certaines limitations pratiques, il y a eu l'idée d'ajouter des variables ressorts dans la maximisation de la marge [**54**]. Ce principe de la marge souple consiste à autoriser des erreurs de classification, ce qui donne aux SVMs la capacité de manipuler des valeurs aberrantes. Le nouveau problème de séparation optimale est reformulé comme suit : l'hyperplan optimal séparant les deux classes est celui qui sépare les données avec le minimum d'erreurs, et qui satisfait les deux conditions suivantes :

— La distance entre les vecteurs bien classés et l'hyperplan doit être maximale.

— La distance entre les vecteurs mal classés et l'hyperplan doit être minimale.

Des variables de pénalité non négatives sont introduites, ζ_i pour $i = 1, \ldots, N$, appelées variables d'écart (voir Figure 1.9) afin de détendre un peu les contraintes sur la marge :

$$z_i(\langle w, x_i \rangle + b) \geq 1 - \zeta_i \quad pour \quad i = 1, \ldots, N. \tag{1.9}$$

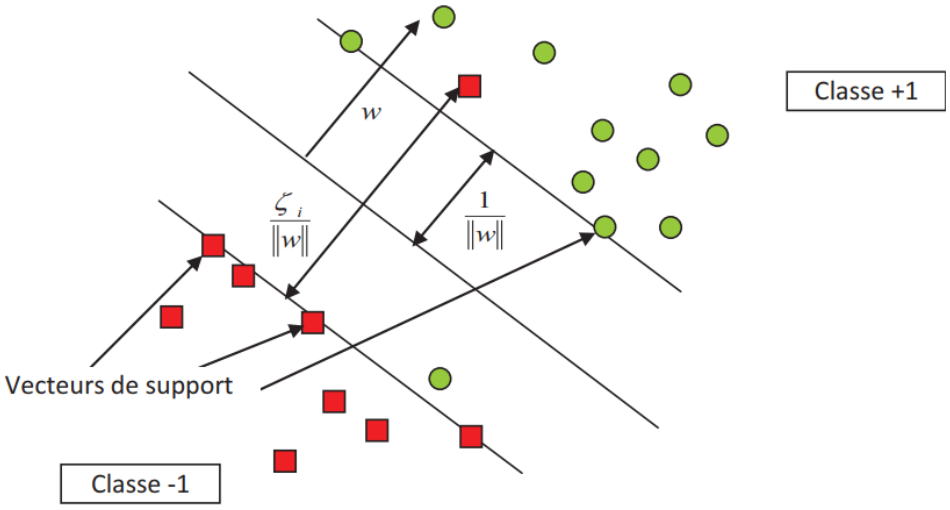


FIGURE 1.9 – Marge souple.

Avec l'introduction d'un terme de pénalité, on obtient le problème dual suivant :

$$\begin{cases} \min\left(\frac{1}{2}\|w^2\| + C\sum_{i=1}^{N}\zeta_i\right) \\ \\ sous \quad les \quad contraintes \\ \\ z_i\left[\langle w, x_i\rangle + b\right] \geq 1 - \zeta_i \quad et \quad \zeta_i \geq 0 \quad pour \qquad i = 1, \ldots, N \end{cases} \tag{1.10}$$

Où le paramètre C ($C \geq 0$) est interprété comme un paramètre de régularisation qui régit la tolérance de mauvaise classification.

L'augmentation de la valeur de C augmente le coût porté sur les points ou les vecteurs mal classés (on autorise plus de points mal classés sur les données d'apprentissage) et en même temps on réduit l'importance donnée à la minimisation de la complexité du modèle (minimisé $\|w\|^2$). Donc par conséquent ce paramètre doit être choisi d'une manière judicieuse afin de garder toujours l'aspect de généralisation des SVMs tout en rejetant les données mal classées.

Ce problème peut être résolu en utilisant les multiplicateurs de Lagrange (α et μ) et le dual lagrangien de ce problème devient :

$$L(w, b, \zeta) = \frac{1}{2}\|w^2\| + C\sum_{i=1}^{N}\zeta_i - \sum_{i=1}^{N}\alpha_i\left(z_i\langle w, x_i\rangle + b\right) + \zeta_i - 1 - \sum_{i=1}^{N}\mu_i\zeta_i \tag{1.11}$$

Le lagrangien doit être minimisé par rapport à w, b, ζ et maximisé par rapport à α et μ.

$$\frac{\partial L}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^{N} \alpha_i z_i x_i \tag{1.12}$$

$$\frac{\partial L}{\partial b} = 0 \quad \rightarrow \quad w = \sum_{i=1}^{N} \alpha_i z_i = 0 \tag{1.13}$$

$$\frac{\partial L}{\partial \zeta_i} = 0 \quad \rightarrow \quad \forall i \quad C - \alpha_i - \mu_i = 0 \tag{1.14}$$

On obtient ainsi le problème dual suivant :

$$\begin{cases} \max_\alpha \left(\sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \alpha_i \alpha_j z_i z_j \langle x_i, x_j \rangle \right) \\ \\ \textit{sous} \quad \textit{les} \quad \textit{contraintes} \\ \\ 0 \leq \alpha_i \leq C \qquad \textit{et} \qquad \sum_{i=1}^{N} \alpha_i z_i = 0 \qquad i = 1, \ldots, N \end{cases} \tag{1.15}$$

Ces multiplicateurs de Lagrange représentent une sorte de forces virtuelles découlant des contraintes posées sur le problème à résoudre.

B. *Fonctions noyaux*

Dans le cas de données non linéairement séparables [**29**], plus la dimension de l'espace de description est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples et les contre-exemples sont élevés. En transformant l'espace d'entrée en un espace de redescription (appelé aussi espace de caractéristique) d'une plus grande dimension, éventuellement infinie, il devient possible d'utiliser la méthode des SVMs (voir Figure 1.10).

Notons ϕ une transformation non linéaire ou mappage « mapping » de l'espace d'entrée x en un espace de redescription $\phi(x)$.

Voici un exemple de projection :

$$x = (x_1, \ldots, x_P)^T \quad \rightarrow \quad \phi(x) = \langle \phi_1(x), \ldots, \phi_P(x) \rangle \tag{1.16}$$

Où $\langle , \rangle$ dénote le produit scalaire dans le nouvel espace.

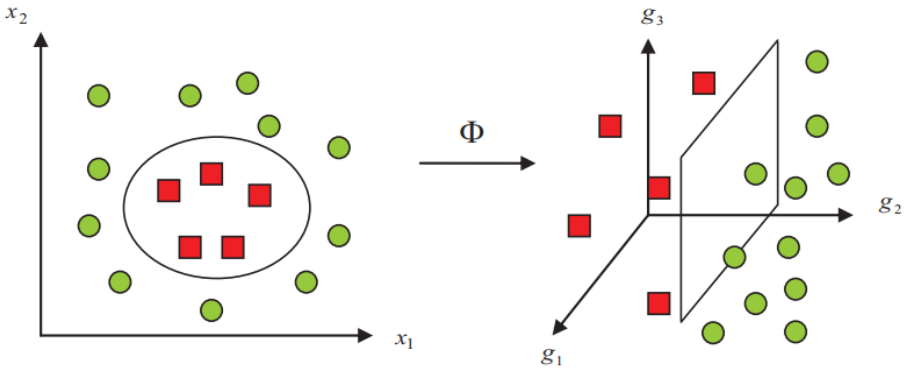


FIGURE 1.10 – Exemple de projection.

Le problème d'optimisation se transcrit dans ce cas par :

$$\begin{cases} \max_\alpha \left(\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \alpha_i \alpha_j z_i z_j \langle \phi(x_i), \phi(x_j) \rangle \right) \\ \\ \textit{sous} \quad \textit{les} \quad \textit{contraintes} \\ \\ 0 \leq \alpha_i \leq C \qquad \textit{et} \qquad \sum_{i=1}^N \alpha_i z_i = 0 \qquad \textit{avec} \qquad i = 1, \ldots, N \end{cases} \tag{1.17}$$

Et la fonction de décision est donnée par :

$$f(x) = \sum_{i=1}^{N} z_i \alpha_i \langle \phi(x_i), \phi(x_j) \rangle + b \tag{1.18}$$

$\langle \phi(x_i), \phi(x_j) \rangle$ devient rapidement impossible à calculer quand la dimension de $\phi(x_i)$ augmente (sans parler du cas de la dimension infinie). Ceci est d'autant plus difficile si on utilise des transformations non linéaires des descripteurs d'entrée. On peut dans certains cas s'arranger pour court-circuiter le passage par les calculs dans l'espace de redescription. Il existe des fonctions bilinéaires symétriques positives $K(x_i, x_j)$, appelées fonction noyaux, faciles à calculer et dont on peut montrer qu'elles correspondent à un produit scalaire $\langle \phi(x_i), \phi(x_j) \rangle$ dans un espace grandes dimensions :

$$K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \tag{1.19}$$

On peut utiliser n'importe quelle fonction noyau $K(x_i, x_j)$ valide satisfaisant la condition de Mercer sans avoir besoin de connaître des informations sur la transformation non

linéaire qu'il y a derrière. La condition de Mercer nous indique si une fonction est un noyau mais ne fournit aucune information sur la fonction ϕ (et donc sur l'espace des caractéristiques) induite par ce noyau.

Condition de Mercer : Sachant que la matrice contenant les similarités entre tous les exemples de l'entraînement est appelée la matrice de Gram (G), la condition ou le théorème de Mercer s'énonce comme suit :

La fonction $K(x_i, x_j) : X \times X \to \mathfrak{R}$ est un noyau si et seulement si la matrice de Gram $G = (K(x_i, x_j))$, avec , $i, j = 1, ..., N$ (N est le nombre d'exemples d'entraînement) est une matrice définie positive.

Notons qu'une fonction $K : X \times X \to \mathfrak{R}$ générant une matrice définie positive G possède les trois propriétés fondamentales du produit scalaire suivantes : $\forall (x_i, x_j) \in X$

1. **Positivité** : $K(x_i, x_i) \geq 0$
2. **Symétrie** : $K(x_i, x_j) = K(x_j, x_i)$
3. **Inégalité de Cauchy-Schwartz** : $|K(x_i, x_j)| \leq \|x_i\| \cdot \|x_j\|$

En pratique, la fonction noyau va déterminer la structure du modèle et donne un aspect de flexibilité à la méthode SVM.

Le problème de classification supervisée donnée par le système (1.17) peut s'écrire d'une autre façon :

$$\begin{cases} \max_{\alpha \in \mathfrak{R}^N} \left(\alpha^T I - \frac{1}{2} \alpha^T \cdot G \cdot \alpha \right) \\ \\ sous \quad les \quad contraintes \\ \\ \alpha^T z = 0 \quad et \quad 0 \leq \alpha_i \leq C \qquad i = 1, \ldots, N \end{cases} \tag{1.20}$$

Avec $\alpha^T = [\alpha_1, ..., \alpha_N]$, $z^T = [z_1, ..., z_N]$, I est un vecteur unitaire de taille N et $G = z_i z_j K(x_i, x_i)$ est la matrice d'influence par paires du terme général. Cette matrice est carrée symétrique définie positive de taille $N \times N$.

Pour décider à quelle classe appartient une donnée x, il suffit de prendre le signe de la fonction de décision donné par (1.18) :

$$f(x) = sgn \left(\sum_{i=1}^{N} z_i \alpha_i K(x_i, x) + b \right) \tag{1.21}$$

Si le signe de $f(x)$ est positif alors la donnée x appartient à la classe $+1$, sinon elle appartient

à la classe –1. Cette fonction est une somme pondérée de fonction noyaux.

Elle dépend juste des N_{sup}, car $\alpha_i = 0$ ailleurs. Donc, on peut remplacer N par N_{sup} :

$$f(x) = sgn\left(\sum_{i=1}^{N_{sup}} z_i \alpha_i K(x_i, x) + b\right) \tag{1.22}$$

La valeur du biais b peut être calculée par l'utilisation de deux supports opposés x_A et x_B tels que $f(x_A) = 1$ et $f(x_B) = -1$:

$$b = -\frac{1}{2}\sum_{i=1}^{N_{sup}} z_i \alpha_i \left[K(x_A, x_i) - K(x_B, x_i)\right] \tag{1.23}$$

C. *Exemples de noyaux*

Noyau linéaire : $K(x_i, x_j) = \langle x_i, x_j \rangle$, avec $\phi(x_i) = x_i$ est la fonction identité.

Noyau polynomial : $K(x_i, x_j) = \langle x_i, x_j \rangle^d$, où d est le degré du polynôme. Ce noyau réalise implicitement un produit scalaire dans l'espace des descripteurs correspondants à tous les produits à d dimensions.

Noyau gaussien (ou noyau RBF) : Cette fonction noyau est typique et très largement utilisée puisqu'elle permet avec un réglage approprié de représenter n'importe quelle fonction. Le noyau gaussien représente une mesure de similarité entre les échantillons (x_i, x_j) et s'écrit sous la forme suivante : $K(x_i, x_j) = exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$, où σ est la variance, qui devient un paramètre de régulation.

Noyau sigmoïde : $K(x_i, x_j) = tanh\left(\langle x_i, x_j \rangle + 1\right)$

D'autres variantes de SVM existent. Dans ce rappel nous citons juste les fonctions noyaux les plus utilisées dans la littérature pour résoudre ce problème de classification.

1.6.2 Classification naïve bayésienne

La classification naïve bayésienne est un type de classification probabiliste simple basé sur le théorème de Bayes avec une forte indépendance (dite naïve) des hypothèses. Elle met en œuvre un classificateur bayésien naïf appartenant à la famille des classificateurs linéaires. Malgré leur modèle de conception « naïf » et ses hypothèses de base extrêmement

simplistes, les classificateurs bayésiens naïfs ont fait preuve d'une efficacité plus que suffisante dans beaucoup de situations réelles complexes. En 2004, un article a montré qu'il existe des raisons théoriques derrière cette efficacité inattendue [**55**]. Toutefois, une autre étude de 2006 montre que des approches plus récentes (arbres renforcés, forêts aléatoires) permettent d'obtenir de meilleurs résultats [**56**].

L'avantage du classificateur bayésien naïf est qu'il requiert relativement peu de données d'entraînement pour estimer les paramètres nécessaires à la classification, à savoir moyennes et variances des différentes variables. En effet, l'hypothèse d'indépendance des variables permet de se contenter de la variance de chacune d'entre elles pour chaque classe, sans avoir à calculer de matrice de covariance.

1.6.2.1 Modèle bayésien naïf

Le modèle probabiliste pour un classificateur est le modèle conditionnel : $p(C|F_1, \ldots, F_n)$, où C est une variable de classe dépendante dont les instances ou classes sont peu nombreuses, conditionnée par plusieurs variables caractéristiques $F_1, \ldots, F_n$.

Lorsque le nombre de caractéristiques n est grand, ou lorsque ses caractéristiques peuvent prendre un grand nombre de valeurs, baser ce modèle sur des tableaux de probabilités devient impossible. Par conséquent, nous le dérivons pour qu'il soit plus facilement soluble.

À l'aide du théorème de Bayes, nous écrivons :

$$p(C|F_1, \ldots, F_n) = \frac{p(C)p(F_1, \ldots, F_n|C)}{p(F_1, \ldots, F_n)} \tag{1.24}$$

En langage courant, cela signifie :

$$posterieure = \frac{anterieure \times vraisemblance}{evidence}$$

En pratique, seul le numérateur nous intéresse, puisque le dénominateur ne dépend pas de C et les valeurs des caractéristiques F_i sont données. Le dénominateur est donc en réalité constant. Le numérateur est soumis à la loi de probabilité à plusieurs variables et peut-être factorisé de la façon suivante, en utilisant plusieurs fois la définition de la

probabilité conditionnelle :

$$\begin{aligned} p(C)p(F_1,\ldots,F_n|C) &= p(C)p(F_1|C)p(F_2,\ldots,F_n|C,F_1) \\ &= p(C)p(F_1|C)p(F_2|C,F_1)p(F_3,\ldots,F_n|C,F_1,F_2) \\ &= p(C)p(F_1|C)p(F_2|C,F_1)\ldots p(F_n|C,F_1,F_2,F_3,\ldots,F_{n-1}) \end{aligned} \tag{1.25}$$

C'est là que nous faisons intervenir l'hypothèse naïve : si chaque F_i est indépendant des autres caractéristiques $F_{j\neq i}$, conditionnellement à C alors :

$$p(F_i|C,F_j) = p(F_i|C) \tag{1.26}$$

pour tout $i \neq j$, par conséquent la probabilité conditionnelle peut s'écrire :

$$p(F_1,\ldots,F_n|C) = p(F_1|C)\ p(F_2|C)\ p(F_3|C)\cdots p(F_n|C) = \prod_{i=1}^{n} p(F_i|C). \tag{1.27}$$

Par conséquent, en tenant compte de l'hypothèse d'indépendance ci-dessus, la probabilité conditionnelle de la variable de classe C peut être exprimée par :

$$p(C|F_1,\ldots,F_n) = \frac{1}{Z}p(C)\prod_{i=1}^{n} p(F_i|C) \tag{1.28}$$

où Z (appelé « évidence ») est un facteur d'échelle qui dépend uniquement de $F_1,\ldots,F_n$, à savoir une constante dans la mesure où les valeurs des variables caractéristiques sont connues.

Les modèles probabilistes ainsi décrits sont plus faciles à manipuler, puisqu'ils peuvent être factorisés par l'antérieur $p(C)$ (probabilité a priori de C et les lois de probabilité indépendantes $p(F_i|C)$. S'il existe k classes pour C et si le modèle pour chaque fonction $p(F_i|C=c)$ peut être exprimé selon r paramètres, alors le modèle bayésien naïf correspondant dépend de $(k-1)+nrk$ paramètres. En effet, pour $C=c$ et un i donné, $p(F_i|C)$ nécessite r paramètres, donc nr paramètres pour tous les F_i, et nrk paramètres pour toutes les classes $C=c$. Reste à déterminer les paramètres $p(C=c)$. On peut en fixer $(k-1)$, sachant que $\sum_c p(C=c)=1$.

Dans la pratique, on observe souvent des modèles où $k=2$ (classification binaire) et $r=1$ (les caractéristiques sont alors des variables de Bernoulli). Dans ce cas, le nombre total de paramètres du modèle bayésien naïf ainsi décrit est de $2n+1$, avec n le nombre

de caractéristiques binaires utilisées pour la classification.

1.6.2.2 Estimation de la valeur des paramètres

Tous les paramètres du modèle (probabilités a priori des classes et lois des probabilités associées aux différentes caractéristiques) peuvent faire l'objet d'une approximation par rapport aux fréquences relatives des classes et caractéristiques dans l'ensemble des données d'entraînement. Il s'agit d'une estimation du maximum de vraisemblance des probabilités. Les probabilités à priori des classes peuvent par exemple être calculées en se basant sur l'hypothèse que les classes sont équiprobables (i.e chaque antérieur = 1 / (nombre de classes)), ou bien en estimant chaque probabilité de classe sur la base de l'ensemble des données d'entraînement (i.e antérieur de C = (nombre d'échantillons de C) / (nombre d'échantillons totaux)). Pour estimer les paramètres d'une loi de probabilité relative à une caractéristique précise, il est nécessaire de présupposer le type de la loi en question ; sinon, il faut générer des modèles non paramétriques pour les caractéristiques appartenant à l'ensemble de données d'entraînement. Lorsque l'on travaille avec des caractéristiques qui sont des variables aléatoires continues, on suppose généralement que les lois des probabilités correspondantes sont des lois normales, dont on estimera l'espérance et la variance.

L'espérance μ, se calcule avec :

$$\mu = \frac{1}{N} \sum_{i=1}^{N} x_i \tag{1.29}$$

où N est le nombre d'échantillons et x_i est la valeur d'un échantillon donné.

La variance, σ^2, se calcule avec

$$\sigma^2 = \frac{1}{(N-1)} \sum_{i=1}^{N} (x_i - \mu)^2 . \tag{1.30}$$

Si, pour une certaine classe, une certaine caractéristique ne prend jamais une valeur donnée dans l'ensemble de données d'entraînement, alors l'estimation de probabilité basée sur la fréquence aura pour valeur zéro. Cela pose un problème puisque l'on aboutit à l'apparition d'un facteur nul lorsque les probabilités sont multipliées. Par conséquent, on corrige les estimations de probabilités avec des probabilités fixées à l'avance.

1.6.2.3 Construire un classificateur à partir du modèle de probabilités

Jusqu'à présent nous avons établi le modèle à caractéristiques indépendantes, à savoir le modèle de probabilités bayésien naïf. Le classificateur bayésien naïf couple se modèle avec une règle de décision. Une règle couramment employée consiste à choisir l'hypothèse la plus probable. Il s'agit de la règle du maximum a posteriori ou MAP. Le classificateur correspondant à cette règle est la fonction classificateur suivant :

$$classificateur(f_1, \ldots, f_n) = argmax_c p(C = c) \prod_{i=1}^{n} p(F_i = f_i | C = c). \tag{1.31}$$

1.6.3 Classification par réseaux de neurones

Le domaine des réseaux de neurones a été initié par des psychologues et des neurobiologistes qui ont cherché à développer et à tester des analogues informatiques de neurones [**57**]. Un réseau de neurones est un ensemble d'unités d'entrée / sortie connectées dans lesquelles chaque connexion est associée à un poids. Pendant la phase d'apprentissage, le réseau apprend en ajustant les poids afin de pouvoir prédire l'étiquette de classe correcte des échantillons d'entrée. L'apprentissage par réseau de neurones est également appelé apprentissage connexionniste en raison des connexions entre les unités [**58**].

Les avantages des réseaux de neurones incluent toutefois leur grande tolérance aux données bruitées ainsi que leur capacité à classer des modèles sur lesquels ils n'ont pas été formés. Ils peuvent être utilisés lorsque nous avons peu de connaissances des relations entre attributs et classes. Ils ont réussi sur un large éventail de données du monde réel, notamment la reconnaissance de caractères manuscrits, la pathologie et le laboratoire de médecine, ainsi que sur la formation d'un ordinateur pour prononcer le texte anglais. Les algorithmes de réseau neuronal sont intrinsèquement parallèles ; des techniques de parallélisation peuvent être utilisées pour accélérer le processus de calcul. De plus, plusieurs techniques ont récemment été développées pour l'extraction de règles à partir de réseaux de neurones formés. Ces facteurs contribuent à l'utilité des réseaux de neurones pour la classification et la prévision numérique dans l'exploration de données.

1.6.3.1 Apprentissage par l'algorithme de rétropropagation

L'algorithme de rétropropagation effectue l'apprentissage sur un réseau de neurones à couches multiples à rétroaction. Il apprend de manière itérative un ensemble de poids permettant de prédire l'étiquette de classe des échantillons. Un réseau neuronal multicouche comprend une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque unité de sortie prend en entrée une somme pondérée des sorties des unités de la couche précédente. Il applique une fonction non linéaire (activation) à l'entrée pondérée. Les réseaux de neurones à rétroaction multicouche peuvent modéliser la prédiction de classe sous la forme d'une combinaison non linéaire d'entrées.

La rétropropagation apprend en traitant de manière itérative un ensemble de données d'apprentissage, en comparant la prédiction du réseau pour chaque couche avec la valeur cible connue réelle. La valeur cible peut être le libellé de classe connu de l'échantillon d'apprentissage (pour les problèmes de classification comme dans notre problème) ou une valeur continue (pour la prédiction numérique). Pour chaque couche d'entraînement, les poids sont modifiés de manière à minimiser l'erreur quadratique moyenne entre la prédiction du réseau et la valeur cible réelle. Ces modifications sont effectuées dans le sens "arrière" à travers chaque couche cachée jusqu'au premier couche cachée (d'où le nom de rétropropagation). Bien que cela ne soit pas garanti, les poids finiront par converger et le processus d'apprentissage arrête. L'algorithme 1.1 est résumé, les étapes sont exprimées en matière d'entrées, de sorties et d'erreurs, et peuvent sembler gênantes s'il s'agit d'un premier regard sur l'apprentissage par réseau neuronal [**59**].

Entrées :

— D, un ensemble de données constitué des couches d'apprentissage et des valeurs cibles associées ;
— l, le taux d'apprentissage ;
— réseau, un réseau multicouche.

Sortie : Un réseau de neurones formés.

(1)- Début {
(2)- Initialiser tous les poids et biais du réseau ;
(3)- **Tant que** la condition finale n'est pas satisfaite ; {
(4)- **Pour** chaque couche d'entraînement X dans D ; {
(5)- Propager les entrées en avant :
(6)- **Pour** chaque unité de couche d'entrée j {

(7)- $O_j = I_j$; la sortie d'une unité d'entrée est sa valeur d'entrée réelle. }

(8)- **Pour** chaque unité de couche cachée ou de sortie j {

(9)- $I_j = \sum_i w_{ij} O_i + \theta_j$; calculer l'entrée nette de l'unité j par rapport à la couche précédente, i.

(10)- $O_j = \frac{1}{1+e^{-I_j}}$; } calculer la sortie de chaque unité j. }

(11)- Rétropropager les erreurs :

(12)- **Pour** chaque unité j dans la couche de sortie {

(13)- $Err_j = O_j(1 - O_j)(T_j - O_j)$; calculer l'erreur.}

(14)- **Pour** chaque unité j dans les couches cachées, de la dernière à la première couche cachée. {

(15)- $Err_j = O_j(1 - O_j) \sum_k Err_k w_{jk}$; calculer l'erreur par rapport à la couche immédiatement supérieure, k. }

(16)- **Pour** chaque poids w_{ij} en réseau {

(17)- $\Delta w_{ij} = (l) Err_j O_i$; augmentation du poids.

(18)- $w_{ij} = w_{ij} + \Delta w_{ij}$; } réactualisation du poids. }

(19)- **Pour** chaque biais θ_j dans le réseau {

(20)- $\Delta \theta_j = (l) Err_j O_i$; augmentation du biais.

(21)- $\theta_j = \theta_j + \Delta \theta_j$; } réactualisation du biais.} }

(22)- Fin Tant que. }

(23)- Fin. }

ALGORITHME 1.1 : Apprentissage du réseau de neurones pour la classification à l'aide de l'algorithme de rétropropagation.

En pratique, plusieurs centaines de milliers d'époques peuvent être nécessaires avant que les poids se convergent.

1.6.4 Classification par arbre de décision

À la fin des années 1970 et au début des années 1980, J. Ross Quinlan, chercheur en apprentissage automatique, a mis au point un algorithme d'arbre décisionnel appelé ID3 (dichotomiseur itératif) [**60**]. Ce travail a développé les travaux antérieurs sur les systèmes d'apprentissage de concepts, décrits dans [**61**] qui est ensuite présenté par C4.5, qui est

devenu une référence à laquelle de nouveaux algorithmes d'apprentissage supervisé sont souvent comparés. En 1984, un groupe de statisticiens a publié le livre Classification and Regression Trees (CART) [**62**], qui décrit la génération d'arbres de décision binaires. Ces deux algorithmes fondamentaux ont engendré une série de travaux sur l'induction de l'arbre de décision.

Un arbre de décision est une structure arborescente de type organigramme, dans laquelle chaque nœud interne désigne un test sur un attribut, chaque branche représente le résultat du test et chaque nœud terminal (ou nœud feuille) contient une étiquette de classe. Le nœud le plus haut dans une arborescence est le nœud racine. Certains algorithmes d'arbre de décision ne produisent que des arbres binaires (où chaque noeud interne se branche sur exactement deux autres noeuds), tandis que d'autres peuvent produire des arbres non binaires.

La classification par arbre de décision ne nécessite aucune connaissance de domaine ni paramétrage, et convient donc à la découverte de connaissances exploratoires. Les arbres de décision peuvent gérer des données multidimensionnelles. Leur représentation des connaissances acquises sous forme d'arbre est intuitive et généralement facile à assimiler par les humains. Les étapes d'apprentissage de classification de l'induction de l'arbre de décision sont simples et rapides. En général, les classificateurs d'arbres de décision ont une bonne précision. Cependant, une utilisation réussie peut dépendre des données disponibles. L'algorithme 1.2 résume le fonctionnement de base d'apprentissage pour l'arbre de décision.

Entrées :

- La partition de données, D, qui est un ensemble des échantillons d'apprentissage et leurs étiquettes de classe associées ;
- liste d'attributs, l'ensemble d'attributs candidats ;
- Méthode de sélection d'attribut, procédure permettant de déterminer le critère de fractionnement selon lequel la «meilleure» partitionne les valeurs de données en classes individuelles. Ce critère consiste en un attribut de fractionnement et, éventuellement, en un sous-ensemble de points de fractionnement.

Sortie : Un arbre de décision.

(1)- Début {
(2)- Créer un noeud N ;
(3)- **Si** les échantillons en D sont tous de la même classe C, {
(4)- **Alors** Retourne N en tant que noeud feuille étiqueté avec la classe C ;}

(5)- **Si** la liste d'attributs est vide, {

(6)- **Alors** Retourne N en tant que nœud feuille étiqueté avec la classe majoritaire en D ;}

(7)- Vote à la majorité appliqué(D, liste d'attributs) pour trouver le «meilleur» critère de fractionnement ;

(8)- Etiqueter le noeud N avec le critère de division ;

(9)- **Si** l'attribut de division est à valeur discrète **Et** que les divisions à plusieurs entrées sont autorisées, {

(10)- **Alors** liste d'attributs ← liste d'attributs - attribut de division (supprime l'attribut de division) }

(11)- **Pour** chaque résultat j du critère de fractionnement (partitionnez les échantillons et développez des sous-arbres pour chaque partition) ; {

(12)- **Soit** D_j l'ensemble des valeurs de données dans D satisfaisant le résultat j ;

(13)- **Si** D_j est vide,

(14)- **Alors** Attachez une feuille étiquetée avec la classe de majorité dans D au nœud N ;

(15)- **Sinon** attacher le nœud renvoyé par Generate decision tree (D_j, liste d'attributs) au nœud N ;

(16)- **Fin Pour** }

(17)- Retourne N ;

(18)- Fin. }

ALGORITHME 1.2 : Apprentissage d'arbre de décision pour la classification.

1.6.5 La logique Floue

Les bases théoriques de la logique floue ont été établies au début des années 1965 par le professeur Zadeh de l'université de Californie de Berkeley [**63**]. Cette technique associe les notions de « sous-ensemble flou » et de « théorie des possibilités ». Il s'agit d'une approche calquée sur le raisonnement humain plutôt que sur des calculs rigides ; pour des problèmes mal définis, l'être humain est irremplaçable.

En effet, le mode de raisonnement en logique floue est plus intuitif que la logique classique. Il permet aux concepteurs de mieux appréhender les phénomènes naturels, imprécis

et difficilement modélisables en s'appuyant sur la définition de règles et de fonctions d'appartenance à des ensembles dits « ensembles flous ».

Les éléments de base de la logique floue sont :
— les variables linguistiques ;
— les fonctions d'appartenance ;
— les déductions aux inférences.

1.6.5.1 Variables linguistiques

La description d'une certaine situation, d'un phénomène ou d'un procédé contient en général des qualificatifs flous tels que :
— peu, beaucoup, énormément
— rarement, fréquemment, souvent
— petit, moyen, grand
— etc....

1.6.5.2 Fonctions d'appartenance

Au lieu d'appartenir à l'ensemble « vrai » ou à l'ensemble « faux » de la logique binaire traditionnelle, la logique floue admet des degrés d'appartenance à un ensemble donné. Le degré d'appartenance à un ensemble flou est matérialisé par un nombre compris entre 0 et 1. Une valeur précise de la fonction d'appartenance liée à une valeur de la variable est notée μ et appelée « facteur d'appartenance ».

Les fonctions d'appartenance peuvent théoriquement prendre n'importe quelle forme. Toutefois, elles sont souvent définies par des segments de droites, et dites « linéaires par morceaux » .(Très utilisées car elles sont simples et comportent des zones où la notion est vraie, des zones où elle est fausse, ce qui simplifie le recueil d'expertise).

Fonctions d'appartenance d'entrée :
— Demi-trapèze gauche ;
— Demi-trapèze droit ;
— Triangle symétrique ou asymétrique ;
— Trapèze symétrique ou asymétrique.

Fonctions d'appartenance de sortie :

— Singletons ou Rectangles Etroits ;
— Triangle / Trapèze.

1.6.5.3 Déductions aux inférences

Plusieurs valeurs de variables linguistiques sont liées entre elles par des règles et permettent de tirer des conclusions. Les règles peuvent alors être exprimées sous la forme générale :

— Si condition 1 alors action 1 ou
— Si condition 2 alors action 2 ou
— Si . . . . . .
— Si condition n alors action n.

Les conditions peuvent dépendre de plusieurs variables liées entre elles par des opérateurs OU ou ET.

1.6.6 Méthode d'optimisation par essaims particulaires "PSO"

En 1995, James Kennedy, socio-psychologue et Russel Eberhart, ingénieur en électricité, s'inspirent du monde du vivant pour mettre en place une métaheuristique : l'optimisation par essaim particulaire (PSO) [**64**]. Cette méthode se base sur la collaboration des individus entre eux : chaque particule se déplace et à chaque itération, la plus proche de l'optimum communique aux autres sa position pour qu'elles modifient leur trajectoire. Cette idée veut qu'un groupe d'individus peu intelligents puisse posséder une organisation globale complexe.

Pour appliquer la PSO il faut définir un espace de recherche constitué de particules et une fonction objective à optimiser. Le principe de l'algorithme est de déplacer ces particules afin qu'elles trouvent l'optimum.

Chacune de ces particules est dotée :

— D'une position, c'est-à-dire ses coordonnées dans l'ensemble de définition.
— D'une vitesse qui permet à la particule de se déplacer. De cette façon, au cours des itérations, chaque particule change de position. Elle évolue en fonction de son meilleur voisin, de sa meilleure position, et de sa position précédente. C'est cette évolution qui permet de tomber sur une particule optimale.

— D'un voisinage, c'est-à-dire un ensemble de particules qui interagissent directement sur la particule, en particulier celle qui a le meilleur critère.

À tout instant, chaque particule connaît :

— Sa meilleure position visitée. On retient essentiellement la valeur du critère calculée ainsi que ses coordonnées.

— La position du meilleur voisin de l'essaim qui correspond à l'ordonnancement optimal.

— La valeur qu'elle donne à la fonction objective car à chaque itération il faut une comparaison entre la valeur du critère donnée par la particule courante et la valeur optimale.

Le voisinage d'une particule est le sous-ensemble de particules de l'essaim avec lequel il a une communication directe. Ce réseau de rapports entre toutes les particules est connu comme la sociométrie, ou la topologie de l'essaim.

On se rend compte, en accord avec Maurice Clerc et Patrick Siarry [**65**], que l'évolution d'une particule est finalement une combinaison de trois types de comportements : égoïste (suivre sa voie suivant sa vitesse actuelle), conservateur (revenir en arrière en prenant en compte sa meilleure performance) et panurgien (suivre aveuglément le meilleur de tous en considérant sa performance). On voit alors que la bio-inspiration à l'origine de l'optimisation par essaim particulaire ressort dans l'algorithme sous la forme d'une intelligence collective : coordination du groupe, instinct individuel et interaction locale entre les individus.

Nous allons donc nous intéresser à cette métaheuristique dans le cadre où elle a, avant tout, été définie à savoir l'optimisation de fonctions continues, telle qu'elle est définie dans les travaux de Michel Gourgand et Sylverin Kemmoé Tchomté [**66**]. L'algorithme de base de la PSO travaille sur une population appelée essaim de solutions possibles, elles-mêmes appelaient particules. Ces particules sont placées aléatoirement dans l'espace de recherche de la fonction objective.

À chaque itération, les particules se déplacent en prenant en compte leur meilleure position (déplacement égoïste) mais aussi la meilleure position de son voisinage. Dans les faits, on calcule la nouvelle vitesse à partir de la formule suivante :

$$V_{k+1} = c_1 * V_k + c_2 * (best_{particule} - position_{particule}) + c_3 * (best_{voisin} - position_{particule}) \quad (1.32)$$

Où :

— V_k et V_{k+1} sont les vitesses de la particule aux itérations k et $k+1$.
— $best_{particule}$ est la meilleure position de la particule.
— $best_{voisin}$ est la meilleure position de son voisinage à l'itération k.
— $position_{particule}$ est la position de la particule à l'itération k.
— c_1, c_2, c_3 sont des coefficients fixés, c_2 est généré aléatoirement à chaque itération et en général, $c_3 = c_2$.

On peut ensuite déterminer la position suivante de la particule grâce à la vitesse que l'on vient de calculer :

$$X_{k+1} = X_k + V_{k+1} \tag{1.33}$$

Où : X_k est la position de la particule à l'itération k.

On génère X_0 et V_0 au début de notre algorithme.

L'algorithme de base est très simple comme présenté ci-dessous, avec g la meilleure position connue de l'essaim, $f(e)$ la fonction objective qui calcule le critère de e, e est l'erreur de sortie entre le système et son modèle de référence.

(1)- Pour chaque particule :

(2)- On initialise sa position ;

(3)- On initialise sa meilleure position p connue comme étant sa position initiale ;

(4)- Si $f(p) < f(g)$, on met à jour la meilleure position de l'essaim ;

(5)- On initialise la vitesse de la particule.

(6)- Tant que l'on n'a pas atteint l'itération maximum ou une certaine valeur du critère :

(7)- Pour chaque particule i :

(8)- On tire aléatoire c_2 et c_3

(9)- On met à jour la vitesse de la particule suivant la formule vue précédemment

(10)- On met à jour la position x_i

(11)- Si $f(x_i) < f(p_i)$,

(12)- On met à jour la meilleure position de la particule ;

(13)- Si $f(p_i) < f(g)$, on met à jour la meilleure position de l'essaim g est l'optimum.

ALGORITHME 1.3 : Algorithme de fonctionnement de la méthode d'optimisation par des essaims particulaires "PSO".

1.7 Conclusion

Dans ce chapitre, d'abord nous avons classifié et modélisé les défauts, puis nous avons présenté les différentes méthodes utilisées dans le domaine du diagnostic de défauts. Ces méthodes sont généralement divisées en deux groupes : méthodes de diagnostic avec modèle et sans modèle. Les premières se basent sur l'existence d'un modèle formel de l'équipement et utilisent généralement les techniques de l'automatique. La deuxième catégorie de diagnostic dès lors qu'un modèle de l'équipement est inexistant ou difficile à obtenir. Dans ce cas de diagnostic à base de données, on utilise les outils de la statistique et de l'intelligence artificielle. Le choix d'une de ces méthodes dépend essentiellement des connaissances disponibles sur le procédé, sans oublier les considérations techniques et économiques.

Par la suite, nous avons donné un rappel des principales commandes tolérantes aux défauts. Les deux types existantes de commande tolérante aux défauts ont été rappelées : la commande tolérante aux défauts passive et active. Les méthodes passives sont basées sur les techniques de conception d'une loi de commande robuste. En revanche, les méthodes actives permettent de traiter des défauts imprévus mais nécessitent une commande reconfigurable et un module de diagnostic.

Finalement, nous avons présenté quelques généralités sur des algorithmes et des techniques intelligents de classification et d'optimisation. Ces outils intelligents peuvent être intégrés par la suite de ce document dans des techniques de diagnostic ou de commande tolérante aux défauts.

Dans le chapitre suivant, nous présenterons une conception architécturale d'énergie d'origine éolienne. Nous présenterons aussi les différents types des systèmes éoliens et leurs caractéristiques. On termine le chapitre par une modélisation du système éolien.

Chapitre 2

Conversion de l'énergie éolienne : Principe et modélisation des turbines

Sommaire

2.1 Introduction 41
2.2 Principe de la conversion d'énergie éolienne 42
2.2.1 Quelques notions sur le vent 42
2.2.2 Notions aérodynamiques « théorie de Betz » 44
2.3 Régulation de la puissance d'une éolienne 47
2.3.1 Principe de contrôle par angle de calage variable 50
2.3.2 Principe de contrôle par décrochage aérodynamique passif 50
2.3.3 Principe de contrôle par décrochage aérodynamique actif 51
2.4 Description du système éolien 52
2.4.1 Modèle des pales 53
2.4.2 Modèle convertisseur et génératrice 54
2.4.3 Modèle du système d'entraînement 55
2.4.4 Le système de contrôle 56
2.4.5 Les données du modèle de système éolienne étudié 58
2.5 Conclusion 59

2.1 Introduction

Une éolienne est une machine utilisant la force motrice du vent. Cette force peut être utilisée mécaniquement, pour produire de l'électricité. On parle de parc éolien ou de ferme

éolienne pour décrire des unités groupées pour la production de l'énergie électrique. Ces unités peuvent être installées en terre ou mer.

Dans ce chapitre, on s'intéresse essentiellement au principe de fonctionnement d'une éolienne et aux modèles mathématiques associés. Ces modèles sont issus des lois de physique pour la partie mécanique et de la mécanique des fluides pour le comportement aérodynamique. D'abord nous détaillons le principe physique de la conversion d'énergie de vent avec une explication de la théorie de Betz, ensuite nous regroupons les types des éoliennes en deux familles de turbines : les aérogénérateurs à axe vertical et les aérogénérateurs à axe horizontal. On s'interesse essentiellement aux éoliennes à vitesse variable et à axe horizontal avec leurs constitutions et leurs principes de fonctionnement, ainsi qu'aux différents types de générateurs utilisés dans cette chaine de conversion. Nous verrons ensuite la modélisation et la commande de système éolien proposé dans cette mémoire.

2.2 Principe de la conversion d'énergie éolienne

L'exploitation efficace de l'énergie du vent est une tâche difficile. Comme pour toutes les sources d'énergie, la problématique du rendement d'exploitation est toujours misé en jeu, même si cette question s'avère spécifique dans le cas des énergies renouvelables dont le gisement est « gratuit » et durable contrairement aux sources d'énergie fossile. Avant d'aborder les aspects techniques de l'étude, nous allons synthétiser les caractéristiques du gisement éolien.

2.2.1 Quelques notions sur le vent

Le vent est causé par le déplacement de la masse d'air qui est dû indirectement à l'ensoleillement de la terre. Par le réchauffement de certaines zones de la planète et le refroidissement d'autres parties, une différence de pression est créée et les masses d'air sont en perpétuel déplacement. C'est pourquoi, le vent est une grandeur stochastique, intermittente qui dépend d'un ensemble de facteurs tels que la situation géographique, les saisons, l'altitude, la température et la hauteur de captage. Elle est élevée surtout pendant la période d'hiver et au niveau des mers (offshore). Le vent est défini par sa direction et sa vitesse.

2.2.1.1 Direction et vitesse du vent

Le vent souffle en principe des zones de hautes pressions vers les zones de basses pressions. Aux latitudes moyennes et aux grandes latitudes, sa direction est cependant modifiée du fait de la rotation de la terre. Le vent devient alors parallèle aux isobares au lieu de leur être perpendiculaire.

En réalité, le vent est mesuré par un anémomètre complété par une girouette qui génère les grandeurs fondamentales que sont la vitesse et la direction. Il en existe plusieurs types classés en deux catégories principales, les anémomètres à rotation et les anémomètres à pression. Les signaux électroniques émis par l'anémomètre sont utilisés par le système de contrôle de l'éolienne pour démarrer l'éolienne lorsque la vitesse du vent atteint approximativement $5m/s$. De même, le système de commande électronique arrête automatiquement l'éolienne si la vitesse du vent est supérieure à $25m/s$ afin d'assurer la protection de l'éolienne.

En effet, pour implanter un parc éolien, la prospection des sites possibles constitue le premier travail à effectuer pour juger de la capacité de production d'une centrale éolienne. Des relevés météorologiques complets sur les sites présumés doivent être effectués au moins pendant une année pour déterminer la possibilité ou non d'implanter le parc. Non seulement il faut connaître la vitesse moyenne du vent, mais aussi sa variation en fonction de l'altitude. Les vents les plus intéressants qui donnent finalement le plus d'énergie annuelle, sont les vents réguliers qui ont une vitesse de 6 à 10 m/s [**67**].

2.2.1.2 L'énergie disponible dans le vent

L'énergie éolienne provient de l'énergie cinétique du vent. En effet, si nous considérons une masse d'air m, qui se déplace avec la vitesse v, l'énergie cinétique de cette masse est donnée par :

$$E_c = \frac{1}{2} m v^2 \tag{2.1}$$

Si, pendant l'unité de temps, cette énergie pouvait être complètement récupérée à l'aide d'une hélice qui balaie une surface S, située perpendiculairement à la direction de la vitesse du vent, la puissance instantanée fournie serait, alors :

$$P_0 = \frac{1}{2} \rho S v^3 \tag{2.2}$$

Avec S : la surface d'aire balayée par les pales ; ρ : la masse volumique de l'air, en général elle est égale $1.225kg/m^3$ à la pression atmosphérique à 15^oC ; v : vitesse du vent (m/s).

Cependant, cette puissance ne pourra jamais être extraite dans sa totalité par le dispositif de conversion (aérogénérateur), à cause de la vitesse non nulle des masses d'air derrière lui [**68**]. Donc, il est important de rappeler quelques notions théoriques de l'aérodynamique.

2.2.2 Notions aérodynamiques « théorie de Betz »

2.2.2.1 Le coefficient de puissance

La théorie globale du moteur éolien à axe horizontal a été établie par le savant Allemand Albert Betz dans les années 1919. Betz suppose que le moteur éolien est placé dans un air animé à l'infini en amont d'une vitesse v_1 et à l'infini en aval d'une vitesse v_2 (voir Figure 2.1). La production d'énergie ne pouvant se faire que par la conversion de l'énergie cinétique, la vitesse v_2 est nécessairement inférieur à v_1.

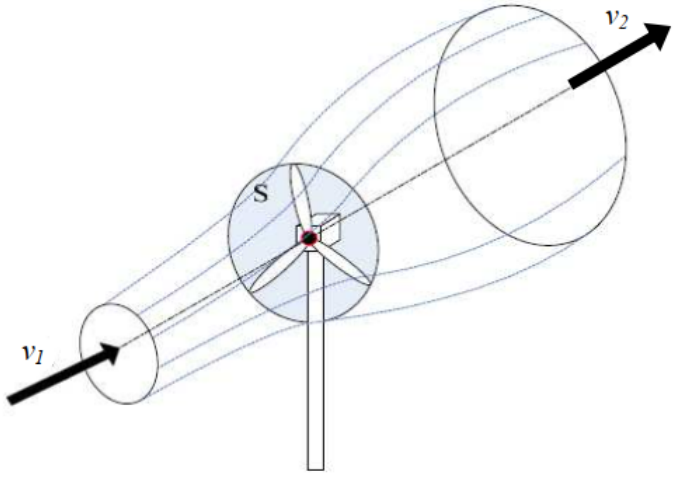


FIGURE 2.1 – Tube de courant autour d'une éolienne.

En supposant que la vitesse du vent traversant le rotor est égale à la moyenne entre la vitesse du vent non perturbé à l'avant de l'éolienne v_1 et la vitesse du vent après passage à travers le rotor v_2 soit $\frac{v_1+v_2}{2}$.

La masse d'air en mouvement de densité ρ traversant la surface S des pales en une

seconde est donnée par :

$$m = \frac{1}{2}\rho S (v_1 + v_2) \tag{2.3}$$

La puissance P_t alors extraite s'exprime par la moitié du produit de la masse et de la diminution de la vitesse du vent (seconde loi de Newton) :

$$P_t = \frac{1}{2} m (v_1^2 - v_2^2) \tag{2.4}$$

Soit en remplaçant l'expression (2.3) dans (2.4), on obtient :

$$P_t = \frac{1}{4}\rho S (v_1 + v_2)(v_1^2 - v_2^2) \tag{2.5}$$

Un vent théoriquement non perturbé traverserait cette même surface S sans diminution de vitesse, soit à la vitesse v_1, la puissance P_0 correspondante serait alors :

$$P_0 = \frac{1}{2}\rho S v_1^3 \tag{2.6}$$

Le ratio entre la puissance extraite du vent et la puissance totale théoriquement disponible est alors :

$$\frac{P_t}{P_0} = \frac{1}{2}\left(1 + \left(\frac{v_2}{v_1}\right)\right)\left(1 - \left(\frac{v_2}{v_1}\right)^2\right) \tag{2.7}$$

Si on représente la caractéristique correspondant à l'équation (2.7), on s'aperçoit que le ratio P_t/P_0 appelé aussi coefficient de puissance C_p présente un maxima de 16/27 soit 0.593. C'est cette limite théorique appelée limite de Betz qui fixe la puissance maximale extractible pour une vitesse de vent donnée.

Cette limite n'est en réalité jamais atteinte et chaque éolienne est définie par son propre coefficient de puissance exprimé en fonction de l'angle de calage des pâles β et la vitesse relative λ ([**69**]), représentant le rapport de la vitesse tangentielle de l'extrémité des pales de l'éolienne (Ω_t R) sur la vitesse instantanée du vent v. Alors l'expression du coefficient de puissance est donc la suivante :

$$C_p = C_p(\lambda, \beta) \tag{2.8}$$

Avec :

$$\lambda = \frac{R \cdot \Omega_t}{v} \tag{2.9}$$

Où Ω_t est la vitesse mécanique de rotation de l'aérogénérateur en $[rad/s]$, et R : le rayon

de la turbine éolienne en $[m]$.

Donc, la limite de Betz caractérise l'aptitude de l'aérogénérateur à capter de l'énergie éolienne. La puissance correspondante est donc donnée par :

$$P_t \;=\; \frac{1}{2}\,\rho\,\pi\,R^2\,v^3\,C_p(\lambda,\beta) \tag{2.10}$$

De cette façon, la puissance maximale pouvant être recueillie par une éolienne est calculée à la limite de Betz :

$$P_t^{\max} \;=\; \frac{1}{2}\,\rho\,\pi\,R^2\,v^3\,C_p^{\max} \;=\; 0.593 \;\cdot\; P_0 \tag{2.11}$$

Où $C_p^{\max}$ est le coefficient de puissance maximal.

Sous cette forme, la formule de Betz montre que l'énergie maximale susceptible d'être extraite par un aérogénérateur ne peut dépasser en aucun cas 59.3% de l'énergie cinétique de la masse d'air qui le traverse par seconde [**70**].

Ainsi, on peut définir la notion de rendement aérodynamique η_a de l'éolienne par le rapport :

$$\eta_a \;=\; \frac{C_p}{C_p^{\max}} \;=\; \frac{C_p}{0.593} \tag{2.12}$$

En pratique, la valeur du maximum du coefficient de puissances approche de la valeur de 0.48 avec une turbine tripale. Ce qui donne un rendement aérodynamique de 81% pour les turbines éoliennes actuelles [**71**].

Le graphique de la figure 2.2 donne une vue sur les coefficients de puissance C_p habituels en fonction de la vitesse réduite pour différents types d'éoliennes [**72**] :

2.2.2.2 Le coefficient du couple

Le coefficient du couple C_c est assez proche du coefficient de puissance C_p. Il est fort utile afin de calculer la valeur des couples produite pour différents points de fonctionnement notamment à vitesse de rotation Ω_t nulle. En effet, au démarrage, il y a bien un couple sur l'arbre dû à la force du vent sur les pales tandis que la puissance est nulle, ce qui correspond à une valeur de C_p nulle pour une valeur de C_c non nulle.

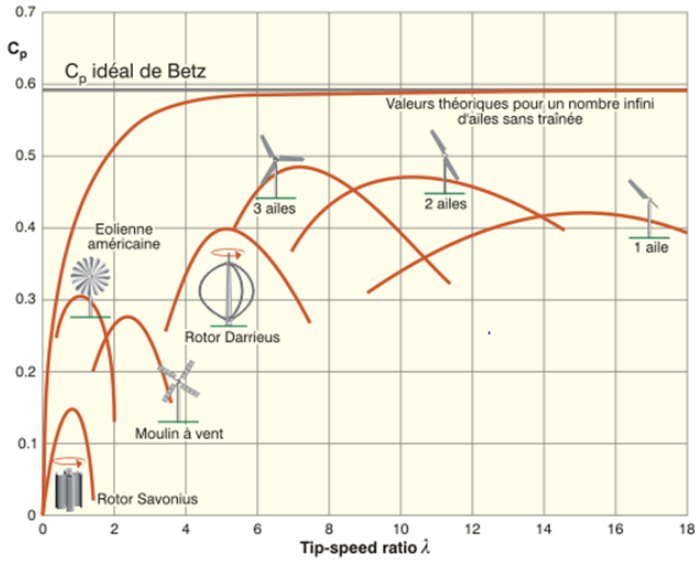


FIGURE 2.2 – Coefficient de puissance pour différents types d'éoliennes.

L'expression du couple est donc la suivante :

$$C_t = \frac{P_t}{\Omega_t} = \frac{R \cdot P_t}{\lambda \cdot v} = \frac{1}{2}\frac{C_p}{\lambda}\,\rho\,\pi\,R^3\,v^2 \tag{2.13}$$

Et alors, la valeur du coefficient du couple C_c est déterminée par la formule suivante :

$$C_c = \frac{C_p}{\lambda} = \frac{C_t}{\frac{1}{2}\,\rho\,\pi\,R^3\,v^2} \tag{2.14}$$

Le coefficient C_c s'exprime, comme le coefficient C_p, en fonction de la vitesse du vent v et de la vitesse de rotation de la turbine Ω_t, donc en fonction du ratio de vitesse λ.

2.3 Régulation de la puissance d'une éolienne

Les objectifs de la régulation sont d'assurer la sécurité de l'éolienne par vents forts d'une part et délimiter la puissance extraite par la turbine éolienne d'autre part. En effet, cette turbine est dimensionnée pour développer sur son arbre une puissance nécessaire, dénommée puissance nominale P_n. Cette puissance P_n est obtenu à partir de la vitesse v_n (vitesse nominale) du vent relatif. Lorsque la vitesse du vent est supérieure à v_n la turbine éolienne doit modifier ses paramètres afin d'éviter sa destruction mécanique, en faisant de sorte que sa vitesse de rotation reste pratiquement constante.

A coté de la vitesse nominale v_n qui varie entre $11m/s$ et $15m/s$ en fonction des technologies [**73**], on spécifie aussi :

— La vitesse de démarrage v_D (cut-in), à partir de laquelle l'éolienne commence à fournir de l'énergie. Selon les constructeurs, v_D varie entre $2.5m/s$ et $4m/s$ pour les éoliennes de forte puissance.

— La vitesse maximale du vent v_M (cut-off), pour laquelle la turbine ne convertit plus l'énergie éolienne, pour des raisons de sûreté de fonctionnement. Pour la grande majorité des éoliennes, v_m vaut $25m/s$.

Quatre zones principales de fonctionnement peuvent être distinguées (voir figure 2.3) :

La zone I : la vitesse du vent est trop faible. La turbine peut tourner mais l'énergie à capter est négligeable ($P = 0$).

La zone II : dans laquelle la puissance fournie sur l'arbre dépend de la vitesse du vent V. Lorsque la vitesse de la génératrice atteint une valeur seuil, un algorithme de commande sera appliqué pour permettre à la turbine d'extraire la puissance maximale du vent. Pour ce but, l'angle de calage des pales β est maintenu constant à sa valeur minimale (généralement $\beta = 0°$). Cette zone correspond au fonctionnement à charge partielle.

La zone III : Corresponds aux vitesses de vent élevées pour lesquelles la vitesse de rotation de la turbine est limitée à une valeur maximale pour limiter la puissance P fournie par l'éolienne égale à la puissance nominale P_n, afin de ne pas subir de dégâts. Cette zone correspond au fonctionnement à pleine charge.

La zone IV : lorsque la vitesse du vent dépasse la vitesse maximale admissible par l'éolienne V_M, les pales de la turbine sont mises en drapeaux ($\beta = 90°$) afin de protéger la partie mécanique de l'éolienne et d'éviter son endommagement. Dans ce cas, la turbine s'arrête et la puissance extraite par l'aérogénérateur sera nul ($P = 0$).

Généralement, il existe quatre systèmes de régulation pour contrôler la vitesse de l'éolienne par rapport à la vitesse du vent. Autrement dit, pour limiter la puissance extraite de la turbine, à la valeur de la puissance nominale de la génératrice :

1. Le système à calage ou à pas variable qui permet d'ajuster la portance des pales à la vitesse du vent pour maintenir une puissance sensiblement constante dans la zone III de vitesse. Cette technique est plutôt utilisée sur les éoliennes à vitesse variable de moyenne et fortes puissances.

2. Le système à décrochage aérodynamique passif, le plus robuste car c'est la forme

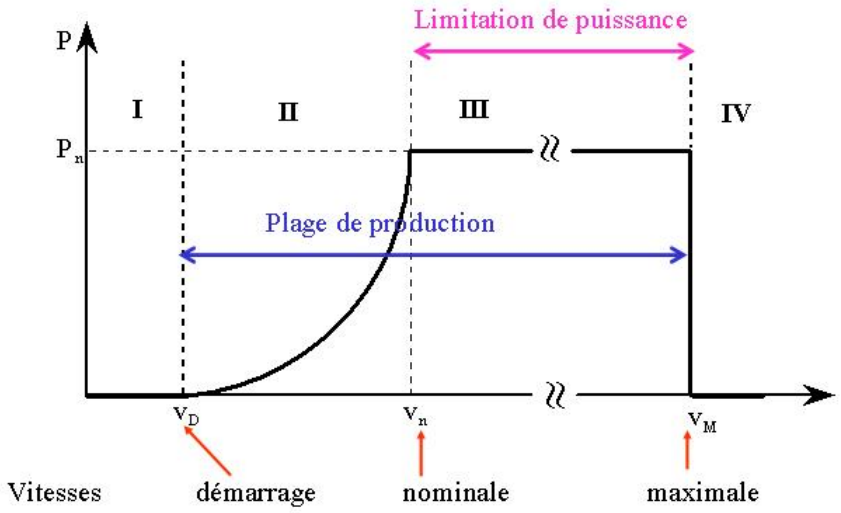


FIGURE 2.3 – Courbe typique d'une turbine éolienne.

des pales qui conduit à une perte de portance au-delà d'une certaine vitesse de vent, mais la courbe de puissance chute plus vite : il s'agit donc d'une solution passive. Ce système de contrôle est généralement destiné aux éoliennes à vitesse fixe.

3. Le système à décrochage aérodynamique actif, ce n'est qu'une combinaison des deux méthodes précédemment citées. Les turbines les plus modernes et de grande capacité utilisent déjà cette technique comme le proposent certains fabricants danois. Pour les vents faibles et modérés, et pour le réglage sur la plage à puissance nominale, les pales sont orientées de façon à forcer la perte de portance, ce qui est équivalent à la méthode à décrochage aérodynamique passif.

4. Le système d'orientation, pour les vents supérieurs à v_m (vent élevé), un dispositif oriente automatiquement la nacelle face au vent grâce à une mesure de la direction du vent effectuée par la girouette située à l'arrière de la nacelle, ce qui annule toute conversion d'énergie. Ce type de commande est cependant limité aux petites turbines éoliennes car cette méthode engendre des efforts mécaniques importants au niveau du mât et des pales. Les éoliennes de plus grandes tailles ne peuvent pas adopter cette méthode de régulation de puissance sans provoquer des efforts pouvant endommager l'éolienne.

Les trois premiers systèmes de commande aérodynamiques sont intéressants pour le contrôle des éoliennes de grande puissance, la partie suivante explique brièvement ces trois stratégies :

2.3.1 Principe de contrôle par angle de calage variable

L'angle d'incidence α peut être diminué (ou augmenté) fortement par augmentation (ou diminution) de l'angle de calage β de quelques dizaines de degrés (20 à 30° généralement). Les forces aérodynamiques s'exerçant sur les pales sont donc ainsi réduites (à la fois pour la portance et pour la trainée). Le couple est maintenu pratiquement constant et peut-être annulé par « mise en drapeau » des pales ($\beta = 90°$) à la vitesse maximale, la puissance est donc limitée. Ce type de commande est plus utilisé pour les éoliennes de moyenne et grande taille [**74**].

Les avantages : La diminution de l'angle d'incidence α jusqu'à une valeur nulle ou négative limite toutes les forces aérodynamiques sur les pales, ce qui réduit considérablement les efforts à vitesse de vent élevée. Comme la force de poussée axiale est également diminuée, les efforts sur la tour sont réduits. Cet avantage est encore amplifié à vitesse variable puisque l'excès d'énergie pendant une rafale (dont la variation est trop brutale pour que le mécanisme d'orientation puisse compenser les effets) peut être stocké dans l'inertie du rotor par variation de sa vitesse (si le générateur l'accepte) alors que la puissance transmise reste pratiquement constante. Donc, il n'y a pas besoin des freins mécaniques puissants pour les arrêts d'urgence, un frein de « parking » est suffisant. Les éoliennes qui possèdent ce système de régulation mécanique peuvent fournir plus d'énergie que les éoliennes à décrochage dans les mêmes conditions de fonctionnement, même quand la densité de l'air est faible (sites sur les hauteurs ou de grandes températures).

Les inconvénients : Les actionneurs nécessaires sont de puissance supérieure à celles du système « stall ». L'énergie nécessaire aux actionneurs doit être transmise au moyeu de la turbine ; si les actionneurs sont électriques, cela nécessite également des contacts glissants bagues/charbons sujets à l'usure et nécessitant un entretien. De plus, le système de commande a besoin d'une sensibilité suffisante pour suivre les variations du vent, ce qui augmente les coûts.

2.3.2 Principe de contrôle par décrochage aérodynamique passif

Ce type de commande en boucle ouverte est basé sur une conception appropriée du profil de la pale. Lorsque la vitesse du vent dépasse la valeur nominale, le flux d'air du côté supérieur de la pale commence à perdre de la vitesse, ce qui forme des vortex, ces turbulences causent une perte de sustentation aérodynamique de la pale et permet la dissipation

de l'excès de puissance. Cette commande agit uniquement pour limiter la puissance à des vents forts, régulant la puissance à sa valeur nominale ou plus faible [**75**]. Le fonctionnement à vents faibles reste sans aucune commande donc la puissance obtenue dépend des caractéristiques mécaniques de la turbine et des caractéristiques électriques de la machine.

Les avantages : Ce concept simple et normalement robuste ne fait intervenir aucun système mécanique ou électrique auxiliaire, ce qui facilite la maintenance et baisse le coût d'entretien et de fabrication.

Les inconvénients : Suivant les indications, on constate que la commande « passive stall » ne peut pas garder la puissance capturée P_m à une valeur constante. Elle peut dépasser la puissance nominale à quelques vitesses du vent, qui n'est pas une situation souhaitable.

2.3.3 Principe de contrôle par décrochage aérodynamique actif

L'angle d'incidence α peut être augmenté (ou diminué) légèrement par diminution (ou augmentation) de l'angle de calage β de quelques degrés (3° à 5° généralement). Le décrochage peut être légèrement avancé (ou retardé). Le couple est maintenu pratiquement constant jusqu'au décrochage total où il chute rapidement. La puissance peut donc être limitée à sa valeur nominale.

Les avantages : Il y a possibilité d'adaptation de la turbine aux conditions d'exploitation. Les actionneurs électriques ou hydrauliques nécessaires sont de taille réduite. Les mouvements de rotation des pales restant de faible amplitude. La possibilité de provoquer un décrochage volontairement facilite les conditions de freinage. Le frein mécanique peut être monté derrière le multiplicateur de vitesses où le couple est plus faible, et il n'est utilisé que comme frein de « parking ».

Les inconvénients : Comme ce système de mécanique profite des avantages du système « pitch », il possède donc les mêmes inconvénients de ce dernier, à savoir le coût élevé de fabrication et d'entretien ainsi la difficulté de maintenance.

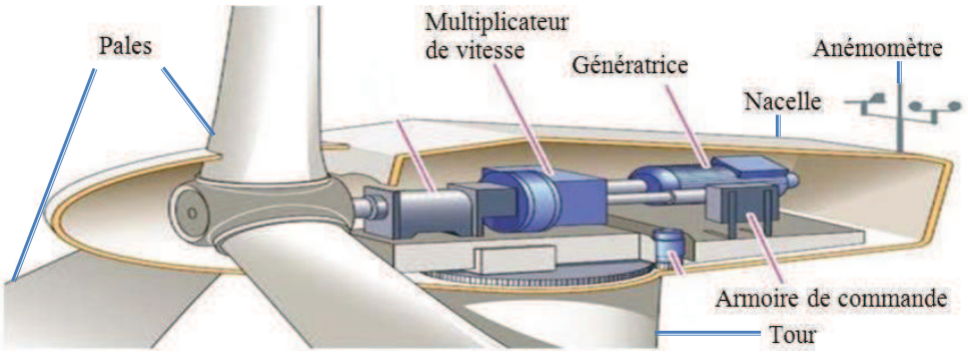


FIGURE 2.4 – Coupe transversale d'une nacelle d'éolienne.

2.4 Description du système éolien

Dans ce document, nous avons consacré le modèle d'éolienne à axe horizontal (HAWT) (voir Figure 2.4). Ce modèle décrit un type spécifique d'éoliennes à vitesse variable à axe horizontal d'une puissance nominale de 4.8 Mw qui sont une hélice perpendiculaire au vent, composée de trois pâle et d'un convertisseur complet [**76**].

Il faut noter que la modélisation des éoliennes tient compte de l'endroit de son implantation, une modélisation de l'éolienne placée en terre ferme étant différente de celle placée dans la mer offshore [**77**]-[**78**].

Dans ce travail, le modèle de référence utilisé est supposé pour une éolienne en terre introduit par [**76**] incluant des défauts de capteurs, d'actionneurs et du système afin d'évaluer les stratégies de diagnostic de défauts et de commande tolérante aux défauts.

La modélisation de l'éolienne représente principalement ses caractéristiques aérodynamiques, mécaniques et électrotechniques. La figure 2.5 représente le schéma-bloc de la structure du modèle éolien utilisé dans ce document.

Ce modèle contient un rotor avec les pales qui permettent de capter l'énergie cinétique du vent. Un train d'entraînement est utilisé pour augmenter la vitesse de rotation du rotor au générateur. Un convertisseur intégral couplé à un générateur permet de convertir l'énergie mécanique en énergie électrique. Un contrôleur cherche à optimiser le fonctionnement de l'éolienne.

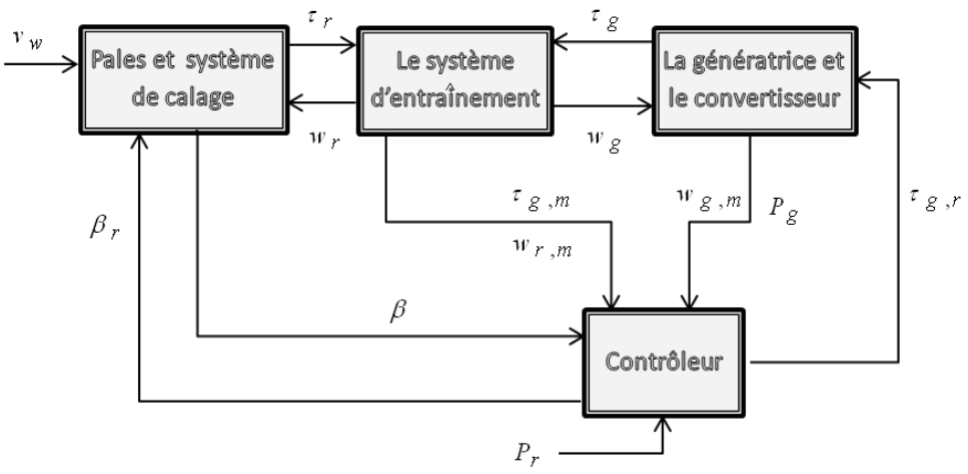


FIGURE 2.5 – Schéma des sous-modèles de système éolien.

2.4.1 Modèle des pales

Ce système est une combinaison du modèle aérodynamique et du modèle de calage des pales :

2.4.1.1 Modèle aérodynamique de l'éolienne

Le couple aérodynamique qui agit sur les pales est donné comme suit [**79**] :

$$\tau_r = \frac{\rho \cdot \pi \cdot R^3 \cdot C_q(\lambda(t), \beta(t)) \cdot \nu_w(t)^2}{2} \tag{2.15}$$

Où $C_q(\lambda, \beta)$ est le coefficient de couple aérodynamique, β est l'angle de calage des pâles « pitch », R le rayon de pales, ν_w est la vitesse du vent, ρ est la densité de l'air et $\lambda = \frac{\omega_r.R}{\nu_w}$ correspond au rapport de vitesses à la pointe (vitesse spécifique).

Pour modéliser le fait que les trois pâles peuvent avoir des valeurs différentes de l'angle de calage β, le couple aérodynamique devient :

$$\tau_r = \sum_{i=1}^{3} \frac{\rho \cdot \pi \cdot R^3 \cdot C_q(\lambda(t), \beta_i(t)) \cdot \nu_w(t)^2}{2} \tag{2.16}$$

Ce modèle est valable pour les petites différences entre les valeurs, comme les tailles utilisées

dans ce modèle, dans les simulations de comparaison, il a été constaté que ce modèle simple a un comportement similaire à celui d'un modèle plus détaillé.

2.4.1.2 Modèle du système de calage des pales

Le système de pas hydraulique est modélisé comme une fonction de transfert en boucle fermée du système de pas hydraulique. En principe, ce système peut être modélisé par une fonction de transfert de 2ème ordre [**80**], avec des contraintes sur chaque pale :

$$\frac{\beta_i(s)}{\beta_{i,ref}(s)} = \frac{w_n^2}{s^2 + 2 \cdot \zeta \cdot w_n \cdot s + w_n^2} \tag{2.17}$$

qui peut être reécrit comme une équation différentielle :

$$\ddot{\beta}_i(t) = -2 \cdot \zeta \cdot w_n \dot{\beta}_i(t) - w_n^2 \cdot \beta_i(t) + w_n^2 \cdot \beta_{i,ref}(t) \tag{2.18}$$

Où $\beta_i(s)$ et $\beta_{i,ref}(s)$ sont les positions mesurées et désirées d'angle de calage des pales. $i = 1, 2, 3$, w_n est la pulsation et ζ est le coefficient d'amortissement.

2.4.2 Modèle convertisseur et génératrice

Les dynamiques du convertisseur sont modélisées par une fonction de transfert du 1ème ordre :

$$\frac{\tau_g(s)}{\tau_{g,r}(s)} = \frac{\alpha_{gc}}{s + \alpha_{gc}} \tag{2.19}$$

Où $\alpha_{gc} = 50s^{-1}$ est le paramètre du modèle.

Cette dynamique peut être approchée par un modèle du premier ordre à constante de temps t_g :

$$\dot{\tau}_g(t) = -\frac{1}{t_g}\tau_g(t) + \frac{1}{t_g}\tau_{g,r}(t) \tag{2.20}$$

Où τ_g et $\tau_{g,r}$ sont respectivement le couple réel et celui désiré.

La puissance produite par la génératrice est :

$$P_g(t) = \eta_g \cdot \omega_g(t) \cdot \tau_g(t) \tag{2.21}$$

Où η_g est le rendement de la génératrice.

2.4.3 Modèle du système d'entraînement

Le système d'entraînement à deux masses est souvent utilisé lors de l'analyse de l'interaction de l'éolienne avec la grille, parce que, du fait de ses vibrations de torsion, le dispositif d'entraînement a une influence significative sur les fluctuations de puissance (voir Figure 2.6).

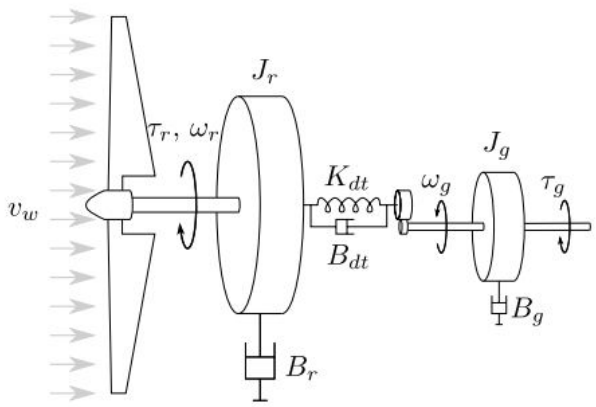


FIGURE 2.6 – La structure du modèle de système d'entraînement à deux masses.

Ce modèle de système d'entraînement « drive train » est modélisé par un modèle à 3 variables d'états en tenant compte des inerties du générateur et du rotor. Les dynamiques de ce système sont données comme suit :

$$\dot{\omega}_r(t) = \frac{1}{J_r}\tau_r(t) - \frac{K_{dt}}{J_r}\theta_\Delta(t) - \frac{(B_{dt}+B_r)}{J_r}\omega_r(t) + \frac{B_{dt}}{J_r N_g}\omega_g(t) \tag{2.22}$$

$$\dot{\omega}_g(t) = \frac{\eta_{dt}K_{dt}}{J_g N_g}\theta_\Delta(t) + \frac{\eta_{dt}B_{dt}}{J_g N_g}\omega_r(t) - \left(\frac{\eta_{dt}B_{dt}}{J_g N_g^2} + \frac{B_g}{J_g}\right)\omega_g(t) - \frac{1}{J_g}\tau_g(t) \tag{2.23}$$

$$\dot{\theta}_\Delta(t) = \omega_r(t) - \frac{1}{N_g}\omega_g(t) \tag{2.24}$$

Dans lesquels, nous pouvons regrouper les équations (2,22), (2,23) et (2,24) de notre

modèle sous la forme de la représentation d'état suivante :

$$\begin{pmatrix} \dot{\omega}_r(t) \\ \dot{\omega}_g(t) \\ \dot{\theta}_\Delta(t) \end{pmatrix} = A \begin{pmatrix} \omega_r(t) \\ \omega_g(t) \\ \theta_\Delta(t) \end{pmatrix} + B \begin{pmatrix} \tau_r(t) \\ \tau_g(t) \end{pmatrix} \tag{2.25}$$

Avec $A = \begin{bmatrix} \frac{-B_{dt}-B_r}{J_r} & \frac{B_{dt}}{N_g J_r} & \frac{-K_{dt}}{J_r} \\ \frac{\eta_{dt} B_{dt}}{N_g J_g} & \frac{\frac{-\eta_{dt} B_{dt}}{N_g^2} - B_g}{J_g} & \frac{\eta_{dt} K_{dt}}{N_g J_g} \\ 1 & \frac{-1}{N_g} & 0 \end{bmatrix}, B = \begin{bmatrix} \frac{1}{J_r} & 0 \\ 0 & \frac{-1}{J_g} \\ 0 & 0 \end{bmatrix}$

Où J_r et J_g sont respectivement le moment d'inertie de l'arbre à faible vitesse et à grande vitesse. K_{dt} est la rigidité de torsion du train d'entraînement, B_{dt} le coefficient de torsion amortie du train d'entraînement, B_r et B_g sont respectivement le frottement visqueux de l'arbre à faible vitesse et à grande vitesse, N_g le rapport de transmission ou d'engrenage, $\theta_\Delta(t)$ est l'angle de torsion du train d'entraînement, et η_{dt} le rendement du train d'entraînement.

2.4.4 Le système de contrôle

La vitesse du vent (précisément sa moyenne) détermine la zone de fonctionnement du contrôleur et par conséquent de la machine éolienne. La figure 2.3 illustre bien différentes zones. Lorsque la vitesse est inférieure à une certaine valeur V_D, l'éolienne est à l'arrêt (**zone I**). Si V_D est dépassé mais inférieure à V_n, le contrôleur fonctionne dans la **zone II** qui correspond à l'optimisation de la puissance. La **zone III** correspond à la saturation (valeur constante) dans la production de puissance quand la vitesse du vent est entre V_n et V_M. Le dépassement de la valeur V_M par la vitesse du vent peut avoir des conséquences néfastes sur l'éolienne. C'est pour cette raison que dans cette **zone IV** l'éolienne est arrêtée.

Le contrôleur proposé dans cette étude a deux modes, le mode 1 correspond à la zone II de vent et le mode 2 à la zone III de vent. Considérons nos données de vent dans la figure 2.7, à un instant plus ou moins $2300s$, la vitesse du vent passe de la zone II à la zone III. Nous pouvons donc supposer que de 0 à $2300s$, le contrôleur Proportionnel Intégral (PI) proposé est en mode 1, puis passe en mode 2 [**81**].

Paramètre	Valeur	Unité
ρ	1.225	kg/m^3
R	57.5	m
ζ	0.6	–
w_n	11.11	rad/s
J_r	$55\,10^6$	$kg.m^2$
K_{dt}	$20.7\,10^9$	$N.m/rad$
B_{dt}	775.49	$N.m.s/rad$
B_r	7.11	$N.m.s/rad$
B_g	45.6	$N.m.s/rad$
N_g	95	–
J_g	390	$kg.m^2$
η_{dt}	0.97	–
η_g	0.98	–
t_g	$20\,10^{-3}$	–

TABLE 2.1 – Les paramètres du modèle d'éolienne traitée dans ce mémoire.

Le mode de contrôle passe du mode 1 au mode 2 si :

$$P_g[n] \geq P_r[n] \vee \omega_g[n] \geq \omega_{nom} \tag{2.26}$$

où $\omega_{nom} = 162 rad/s$ est la vitesse nominale du générateur.

Le mode de contrôle passe du mode 2 au mode 1 si :

$$\omega_g[n] < \omega_{nom} - \omega_\Delta \tag{2.27}$$

Mode 1 de contrôle :

$$\tau_{g,r}[n] = K_{opt} \cdot \left(\frac{\omega_g[n]}{N_g}\right)^2 \tag{2.28}$$

où

$$K_{opt} = \frac{1}{2} \cdot \rho \cdot A \cdot R^3 \cdot \frac{C_{p_{max}}}{\lambda_{opt}^3} \tag{2.29}$$

où A est la surface balayée par les pales de l'éolienne, nous avons donc $A = \pi R^2 = 1.0387 \times 10^4 m^2$ et λ_{opt} est la valeur optimale de λ, $C_{p_{max}}$ est la valeur maximale du coefficient de puissance C_p.

Mode 2 de contrôle : Dans ce mode, les principales actions de contrôle sont gérées

par le système de pitch à l'aide d'un contrôleur PI essayant de garder $\omega_g[n]$ égale à ω_{nom}.

$$\beta_r[n] = \beta_r[n-1] + K_p \cdot e[n] + (K_i \cdot T_s - K_p) \cdot e[n-1] \tag{2.30}$$

où $e[n] = \omega_g[n] - \omega_{nom}$, et les gain de contrôleur du PI sont d'ordre de $K_p = 4$ et $K_i = 1$. Dans ce cas, la référence du convertisseur est utilisée pour supprimer les perturbations rapides de :

$$\tau_{g,r}[n] = \frac{P_r[n]}{\eta_{gc} \cdot \omega_g[n]} \tag{2.31}$$

2.4.5 Les données du modèle de système éolienne étudié

La séquence de la vitesse de vent proposée dans ce mémoire a été choisie, selon l'atlas éolien marocain comme illustré dans la Figure 2.7.

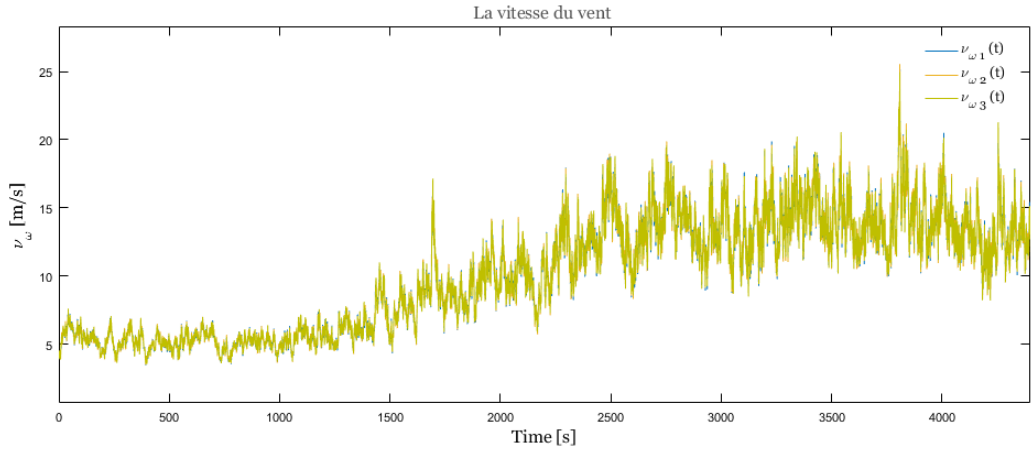


FIGURE 2.7 – Séquence du vitesse de vent proposée dans ce mémoire.

Les références des entrées la référence du couple générateur $\tau_{g,r}(t)$ (voir Figure 2.8) et la référence de l'angle de calage $\beta_r(t)$ (voir Figure 2.9) sont montrées comme suit. Les données du système que nous avons traité sont toutes décrites dans le Tableau 2.1.

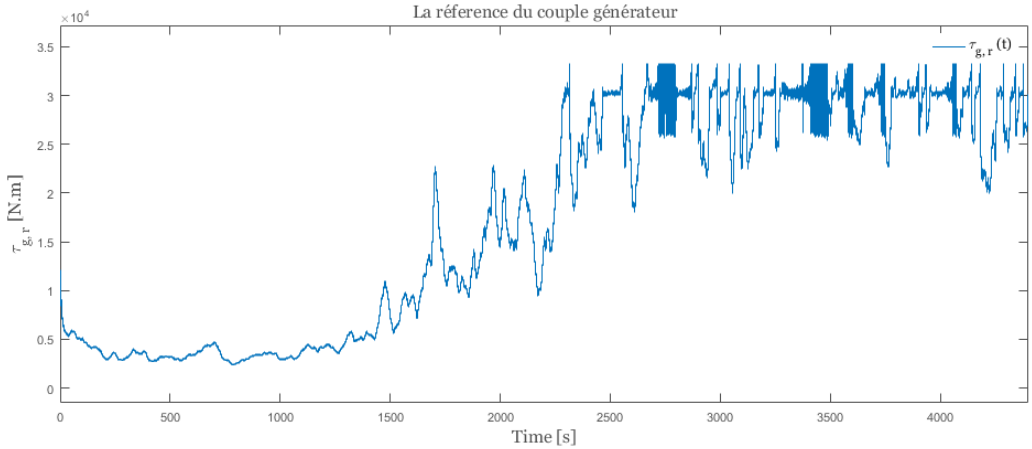


FIGURE 2.8 – Réference du couple générateur $\tau_{g,r}(t)$.

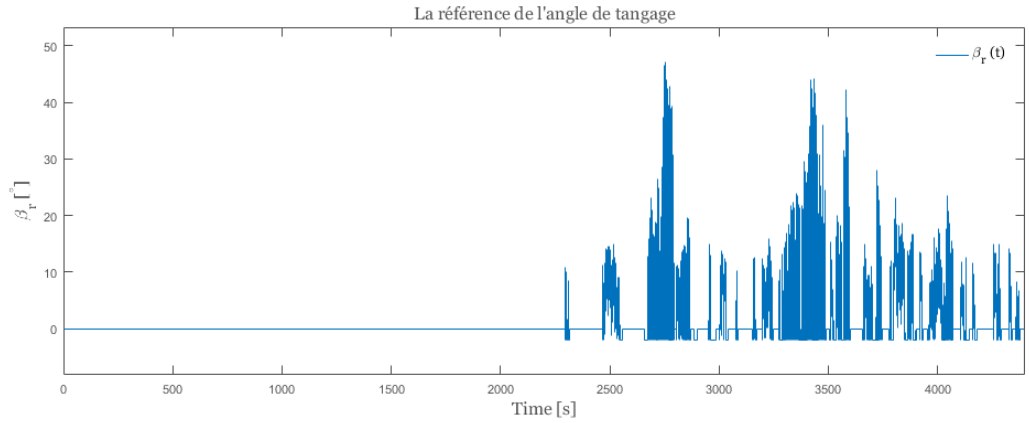


FIGURE 2.9 – Référence de l'angle de calage du pâle $\beta_r(t)$.

2.5 Conclusion

Ce chapitre nous a permis de dresser un panel de solutions électrotechniques possibles pour la production d'énergie électrique grâce à des turbines éoliennes. Après un rappel de notions nécessaires à la compréhension du système de conversion de l'énergie éolienne, différents types d'éoliennes et leur mode de fonctionnement ont été décrits. Par la suite nous avons décrit les trois parties essentielles du système de conversion éolienne, sincèrement la partie mécanique qui contient la turbine et l'arbre de la génératrice.

Dans le chapitre suivant, nous détaillons quelques propositions pour le diagnostic du système éolien.

Chapitre 3

Diagnostic du système éolien

Sommaire

3.1 Introduction 61

3.2 Diagnostic du système éolien à base de modèle 62

3.2.1 Diagnostic du système éolien basé sur le seuillage adaptatif 64

3.2.2 Le diagnostic du système éolien basé sur l'observateur proportionnel multi-intégrales (OPMI) 78

3.2.3 Conclusion 95

3.3 Diagnostic du système éolien à base de données 99

3.3.1 Préparation des données 100

3.3.2 Classifieur basé sur l'adaptation de machine à vecteurs de support (SVM) par la logique floue pour le diagnostic du système éolien . . . 104

3.3.3 Classifieur hybride pour la détection et l'isolation des défauts dans le système éolien 111

3.3.4 Résultats de simulations 112

3.4 Conclusion 117

3.1 Introduction

L'énergie éolienne représente actuellement une des plus importantes ressources d'énergie renouvelable. Ces installations sont généralement situées dans des sites isolés et cela sera renforcé avec le développement des installations off-shore. Il est donc important de mettre en place des techniques de surveillance et de détection de défaut dans les parcs éoliens. Actuellement, chez la plupart des constructeurs d'éoliennes, la détection de défaut est basée sur des dépassements de seuils de certains paramètres.

En général, lorsqu'on parle de diagnostic des défauts, on se réfère à la procédure de détection et d'isolation de ces derniers, que l'on retrouve souvent sous le nom : FDI (Fault Détection and Isolation). Le rôle d'une telle procédure est de fournir une information sur l'apparition d'un défaut et sa provenance le plus rapidement possible. Les méthodes de détection et de localisation des défauts ont connu un essor considérable depuis le début des années 70. En effet, de nombreux chercheurs ont investi dans ce domaine proposant alors diverses approches et techniques répondant à la diversité des applications.

Dans ce chapitre, pour anticiper l'apparition d'un dysfonctionnement, soit pour l'éviter, soit pour en limiter les conséquences, nous avons utilisé des techniques de diagnostic de défauts basées soit sur le modèle ou bien sur les données pour détecter et isoler les défauts de capteurs et d'actionneurs dans les systèmes de la pâle de l'éolienne. Les résultats de la simulation donnés dans cette étude ont été réalisés par MATLAB / SIMULINK, ils permettent de valider l'efficacité des méthodes de diagnostic proposées.

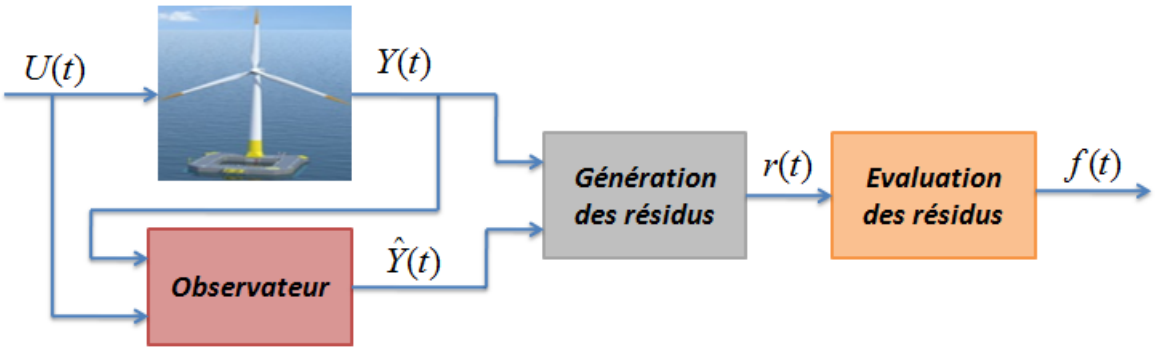


FIGURE 3.1 – Structure principale de diagnostic à base d'observateur pour le système éolien.

3.2 Diagnostic du système éolien à base de modèle

Les méthodes basées sur un modèle explicite utilisent un modèle décrivant les relations fondamentales gouvernant le système afin de générer des symptômes de défauts. Ces méthodes ont de nombreux avantages car elles permettent d'identifier le type du défaut et de remonter à la source du défaut pour différentes classes de systèmes. La plupart des méthodes à base de modèle reposent sur le concept de redondance analytique qui consiste à vérifier la cohérence entre le comportement simulé du modèle et celui réellement observé,

d'où la nécessité d'avoir un modèle détaillé et suffisamment précis du système afin d'avoir des résultats satisfaisants. Ceci est réalisé en générant des résidus qui permettent à leur tour de détecter un écart entre le comportement défectueux et le comportement normal du système. Plusieurs méthodes sont envisageables pour l'obtention de résidus à partir de modèles analytiques.

Dans cette section, le diagnostic du système éolien à base d'observateurs ou bien d'éstimateurs est donné. Ainsi une présentation des méthodes d'évaluation des résidus est évoquée par la suite. Généralement le diagnostic est composé principalement de deux fonctions de base : la génération des résidus et l'évaluation des résidus pour pouvoir décider la présence ou l'absence de défaut (voir Figure 3.1).

La problématique qui se propose dans cette étude est divisée en deux axes de recherche principaux :

— Trouver un observateur ou bien un estimateur qui nous permet d'estimer les sorties du système éolien ;

— Évaluer les résidus générés pour pouvoir décider la présence ou l'absence de défaut.

Pour résoudre cette problèmatique, nous avons proposé deux propositions dans cette section pour ateindre notre objective de diagnostiquer le système éolien. Premièrement, motivé par un observateur et basé sur une architecture générale ainsi qu'un seuil adaptatif, une procédure de FDI actif est dédiée au diagnostic de l'éolienne. L'idée de cette proposition considérée comme un banc d'estimateurs d'isolation de défaut sous la structure DOS (Dedicated Observer Scheme (DOS), voir figure 3.2), et un seuil adaptatif pour pouvoir déterminer le type et l'emplacement de défaut particulier. Le schéma FDI actif proposé est appliqué dans le système éolien et testé lorsque les diverses défaillances se produisent dans les différentes parties du processus. Deuxièment, on traite la détection et l'isolation des défauts pour l'éolienne en se basant sur l'observateur multi intégrales proportionnelles. Dans la première partie, nous avons focalisé l'étude sur la modélisation et la commande du système éolien sous leur forme multimodèle Takagi-Sugeno (TS), par la suite l'observateur multi intégrales proportionnelles est considéré pour estimer et isoler les différents défauts affectant le système. Les défauts actionneurs et capteurs proposés dans cette proposition sont à condition que leurs k-dérivées différentes avec des normes bornées.

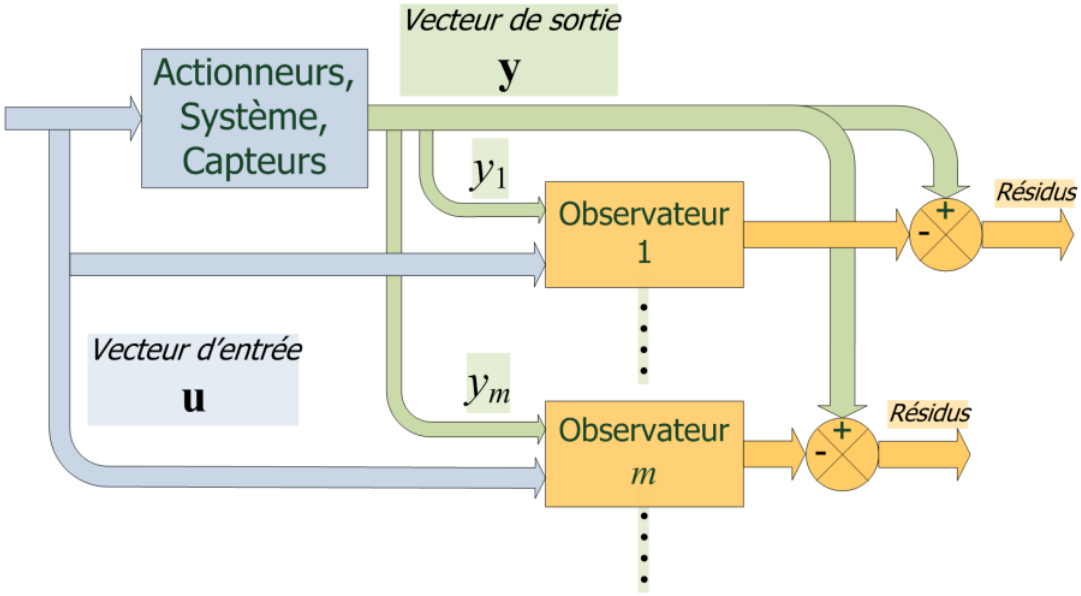


FIGURE 3.2 – Observateur DOS pour la détection des défauts pour le système éolien.

3.2.1 Diagnostic du système éolien basé sur le seuillage adaptatif

La représentation du système d'angle de calage (2.17) en mode de fonctionnement normal peut être reécrit sous la forme :

$$\begin{aligned} \begin{pmatrix} \dot{\beta}_k \\ \ddot{\beta}_k \end{pmatrix} &= A_{pb} \begin{pmatrix} \beta_k \\ \dot{\beta}_k \end{pmatrix} + B_{pb}\beta_r \\ y_{pb} &= C_{pb} \begin{pmatrix} \beta_k \\ \dot{\beta}_k \end{pmatrix} + D_{pb}\beta_r \end{aligned} \tag{3.1}$$

Où $A_{pb} = \begin{bmatrix} -2.\zeta.w_n & -w_n^2 \\ 1 & 0 \end{bmatrix}$, $B_{pb} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$, $C_{pb} = \begin{pmatrix} 1 & 0 \end{pmatrix}$, $D_{pb} = \begin{pmatrix} 0 \end{pmatrix}$, β_k est la position mesurée d'angle de calage de la pale et k indique l'indice de la pâle avec $k = 1, 2, 3$; et β_r est la position désirée d'angle de calage de la pâle.

Le modèle du système générateur (2.19) en mode de fonctionnement normal peut être reécrit sous la forme :

$$\dot{\tau}_g = -\alpha_{gc}\tau_g + \alpha_{gc}\tau_{g,r} \tag{3.2}$$

Où τ_g et $\tau_{g,r}$ sont respectivement le couple réel et le couple souhaité et α_{gc} est le paramètres du modèle.

N°	Description de défaut	Type de défaut	Valeur de défaut	Période (s)
1	Changer l'angle de calage de la pâle 1	Valeur fixe	$\beta_{1,m1} = 5^\circ$	2000-2100
2	Changer l'angle de calage de la pâle 2	Gain	$\beta_{2,m2} = 1.2 * \beta_{2,m2}$	2300-2400
3	Changer l'angle de calage de la pâle 3	Valeur fixe	$\beta_{3,m1} = 10^\circ$	2600-2700
4	Changer la vitesse de rotation du rotor	Valeur fixe	$\omega_{r,m1} = 1.4 rad/s$	1500-1600
5	Changer la vitesse de rotation du rotor et du génerateur	Gain	$\omega_{r,m2} = 1.1 * \omega_{r,m2}$ $\omega_{g,m2} = 0.9 * \omega_{g,m2}$	1000-1100
6	Changement de modèle de calage de la pâle 2 causé par une forte teneur en air dans l'huile	Système	$\omega_{n2} = 11.11 \Rightarrow \omega_{n2} = 5.73$ $\zeta_2 = 0.6 \Rightarrow \zeta_2 = 0.45$	2900-3000
7	Changement de modèle de calage de la pâle 3 provoqué par une chute de pression de la canalisation principale	Système	$\omega_{n3} = 11.11 \Rightarrow \omega_{n3} = 3.42$ $\zeta_3 = 0.6 \Rightarrow \zeta_3 = 0.9$	3400-3500
8	Décalage dans le système de conversion	Décalage	$\tau_g \Rightarrow \tau_g + 2000 Nm$	3800-3900

TABLE 3.1 – Les différents scénarios de défaut considérés dans ce travail.

3.2.1.1 Scénarios de défaillance considéré

Les défauts suivants sont pris en compte dans [**82**] pour ce modèle de référence de l'éolienne :

Défauts dans les systèmes de calage de la pâle : Les défauts de capteurs et d'actionneur dans les systèmes de calage des pâles sont des défauts électriques ou mécaniques. Le défaut 1 est un défaut dans le capteur de type valeur fixe, qui affecte le premier capteur d'angle de calage de la pâle 1 ($\beta_{1,m1}$). Le défaut 2 est un défaut dans le capteur de type produit par un scalaire, qui affecte le deuxième capteur d'angle de calage de la pâle 2 ($\beta_{2,m2}$). Le défaut 3 est un défaut capteur de type valeur fixe, qui affecte le premier capteur d'angle de calage de la pâle 3 ($\beta_{3,m1}$). De plus, deux défauts d'actionneur dans les systèmes

de calage de la pâle sont définis : le défaut 6 associés à l'actionneur de calage de la pâle 2 causé par une forte teneur en air dans l'huile, et le défaut 7 est associé à l'actionneur de calage de la pâle 3 provoqué par une chute de pression de la canalisation principale.

Modèle du système d'entraînement : Les défauts de capteurs et d'actionneur dans le système d'entrainement, ont une influence significative sur les fluctuations de puissance. Le défaut 4 est un défaut dans le capteur de type valeur fixe, qui affecte le premier capteur de vitesse du rotor ($\omega_{r,m1}$) et le défaut 5 est un défaut dans le capteur de type produit par un scalaire, qui affecte à la fois les deuxièmes capteurs de vitesse du rotor et du générateur ($\omega_{r,m2}$, $\omega_{g,m2}$).

Modèle convertisseur et génératrice : Les défauts dans le générateur et le convertisseur, le défaut 8 est un défaut du convertisseur du type additif, qui représente un décalage dans les boucles de commande du convertisseur interne.

Le tableau 3.1 représente les différents scénarios de défaut proposés dans ce travail avec leurs détails.

3.2.1.2 Architecture proposée de diagnostic

La méthode de diagnostic présentée est basée sur l'architecture générale développée par [**83**]. L'architecture de diagnostic comprend un estimateur de détection de panne et un groupe de N estimateurs d'isolement des défauts, avec N est le nombre de défauts considérées. L'estimateur de détection de panne est utilisé pour détecter l'occurrence d'un défaut, et les estimateurs d'isolement des défauts sont utilisés pour déterminer le type et l'emplacement du défaut particulier qui s'est produit. Chaque estimateur d'isolement des défauts est conçu sur la base d'un scénario de défaillance ou d'une hypothèse considérée.

Schéma de la détection de défaut : La décision sur l'apparition d'un défaut (détection) est prise lorsque le module d'au moins un composant du résidu de détection de défaut dépasse son seuil de fonctionnement normal.

Le schéma de décision d'isolation de défaut repose sur le principe intuitif suivant : pour $s = \{1, ..., N\}$, si le défaut s se produit à l'instant T_0 et est détectée à l'instant T_d, un ensemble de seuils peut être conçu pour l'estimateur d'isolement, de telle sorte que chaque composant de son erreur d'estimation de sortie reste inférieure au seuil correspondant, pour tout $t > T_d$.

Par conséquent, pour chaque estimateur d'isolement, un tel ensemble de seuils peut être associé à son erreur d'estimation de sortie. Dans la procédure d'isolation de défauts, si pour chaque estimateur d'isolement, au moins un composant de son erreur d'estimation de sortie dépasse son seuil de fonctionnement normal, alors la possibilité d'occurrence d'un défaut peut être exclu.

Schéma de décision d'isolation de défaut : Supposons que ce défaut $s \in \{1, ..., N\}$ apparaît à l'instant T_0 et est détecté à l'instant T_d. Si, pour chaque estimateur d'isolement des défauts r, $r \in \{1, ..., N\} \setminus \{s\}$, il existe un temps fini $t_r > T_d$, tel qu'au moins un composant de son erreur d'estimation de sortie dépasse le seuil correspondant, alors l'occurrence du défaut s est conclue.

3.2.1.3 Diagnostic pour les systèmes de calage des pâles

Dans cette section, nous présenterons la procédure de diagnostic pour chaque système de calage des pâles en utilisant l'architecture générale décrite ci-dessus :

Diagnostic pour le système de calage de la pâle 1 : L'objectif de la procédure de diagnostic appliquée au modèle de calage de la pâle 1 est de détecter et d'isoler en temps voulu uniquement le défaut de type valeur fixe, qui affecte le premier signal de capteur d'angle de position de calage de la pâle 1 $\beta_{1,m1}$ (défaut 1). Pour atteindre cet objectif, le système de calage de la pâle 1 présenté dans l'équation (3.1) peut réecrit sous la forme :

$$\begin{aligned} \begin{pmatrix} \dot{\beta}_1 \\ \ddot{\beta}_1 \end{pmatrix} &= A_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix} + B_{pb}(\beta_r + \beta_f) \\ y_{pb} &= C_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix} \end{aligned} \tag{3.3}$$

Où β_f est une variable interne utilisée pour modéliser l'erreur de position d'angle de la pâle provoquée par des erreurs de capteurs. Comme décrit ci-dessus, la variable β_f est utilisée pour modéliser l'erreur de position en angle de calage de la pâle à la suite de défaillances du capteur, β_f est donné par :

$$\beta_f = \beta_1 - \frac{1}{2}(\beta_{1,m1} + \beta_{1,m2}) \tag{3.4}$$

En substituant (3.4) en (3.3), on obtient :

$$\begin{gathered}\begin{pmatrix} \dot{\beta}_1 \\ \ddot{\beta}_1 \end{pmatrix} = A_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix} + B_{pb}\beta_r + B_{pb}\left[\beta_1 - \tfrac{1}{2}(\beta_{1,m1} + \beta_{1,m2})\right] \\ y_{pb} = C_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix}\end{gathered} \tag{3.5}$$

puisque nous avons supposé que le premier capteur qui est défectueux $\beta_{1,m1}$ (défaut 1), nous allons considérer :

$$\beta_{1,m1} = \beta_1 = y_{pb} = C_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix} \tag{3.6}$$

Ainsi, en utilisant (3.4), (3.5) et (3.6), la dynamique du système de calage de la pâle 1 devient :

$$\begin{gathered}\begin{pmatrix} \dot{\beta}_1 \\ \ddot{\beta}_1 \end{pmatrix} = (A_{pb} + 0.5B_{pb}C_{pb}) \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix} + B_{pb}(\beta_r - 0.5\beta_{1,m2}) \\ \beta_{1,m1} = C_{pb} \begin{pmatrix} \beta_1 \\ \dot{\beta}_1 \end{pmatrix}\end{gathered} \tag{3.7}$$

Par conséquent, basé sur l'équation (3.7), l'estimateur suivant est choisi pour le premier capteur du système de calage de la pâle 1 $\beta_{1,m1}$:

$$\begin{gathered}\begin{pmatrix} \dot{\hat{\beta}}_1 \\ \ddot{\hat{\beta}}_1 \end{pmatrix} = (A_{pb} + 0.5B_{pb}C_{pb}) \begin{pmatrix} \hat{\beta}_1 \\ \dot{\hat{\beta}}_1 \end{pmatrix} + B_{pb}(\beta_r - 0.5\beta_{1,m2}) + L_{pb}(\beta_{1,m1} - \hat{\beta}_{1,m1}) \\ \hat{\beta}_{1,m1} = C_{pb} \begin{pmatrix} \hat{\beta}_1 \\ \dot{\hat{\beta}}_1 \end{pmatrix}\end{gathered} \tag{3.8}$$

Où $\hat{\beta}_{1,m1}$ est l'estimation de la sortie $\beta_{1,m1}$ et L_{pb} est destiné pour assurer la stabilité de la matrice $A_{pb} + 0.5B_{pb}C_{pb} - L_{pb}C_{pb}$.

Alors l'erreur d'estimation de sortie $R_1 = |\beta_{1,m1} - \hat{\beta}_{1,m1}|$ associé à l'estimateur (3.8) converge vers zéro au cas de fonctionnement normal. Par conséquent, pour pouvoir décider l'état de fonctionnement de système en utilisant le schéma de décision suivant :

— Si R_1 est proche de zéro, Alors le premier capteur $\beta_{1,m1}$ est en bonne santé.

— Sinon R_1 est divergé de zéro, Alors le premier capteur $\beta_{1,m1}$ est défectueux.

De manière uniforme, dans le même scénario de défaillance que celui-ci décrit ci-dessus, nous pouvons déterminer l'estimation du deuxième capteur de la sortie $\beta_{1,m2}$ et nous pouvons décider leur état (défectueux ou sain).

Diagnostic pour le système de calage de la pâle 2 : L'objectif de la procédure de diagnostic appliquée au modèle de calage de la pâle 2 est de détecter et d'isoler en temps voulu deux défauts, un défaut de type gain dans le deuxième capteur de position d'angle de calage de la pâle $\beta_{2,m2}$ (défaut 2) et un défaut actionneur causé par une forte teneur en air dans l'huile (défaut 6). Pour atteindre cet objectif, le système de calage de la pâle 2 présenté dans l'équation (3.1), en absence de défauts $\beta_f = 0$, peut être réecrit sous la forme :

$$\begin{aligned} \begin{pmatrix} \dot{\hat{\beta}}_2 \\ \ddot{\hat{\beta}}_2 \end{pmatrix} &= A_{pb} \begin{pmatrix} \hat{\beta}_2 \\ \dot{\hat{\beta}}_2 \end{pmatrix} + B_{pb}\beta_r + H_{pb}(\beta_2 - \hat{\beta}_2) \\ \hat{\beta}_2 &= C_{pb} \begin{pmatrix} \hat{\beta}_2 \\ \dot{\hat{\beta}}_2 \end{pmatrix} \end{aligned} \tag{3.9}$$

Où H_{pb} est le gain d'observateur choisi pour assurer la stabilité de la matrice $A_{pb} - H_{pb}C_{pb}$.

Clairement, l'erreur d'estimation de sortie $|\beta_2 - \hat{\beta}_2|$ converge vers zéro en absence de fautes. Semblables aux méthodes décrites ci-dessus, deux scénarios sont conçus pour le système de calage de la pâle 2. Le premier résidu correspond au premier capteur R_{21} et le deuxième résidu correspond au deuxième capteur R_{22}.

Notez que, pour ce problème spécifique considéré, l'architecture d'isolation des défauts est simplifiée en utilisant deux estimateurs ci-dessus au lieu de trois scénarios. Plus précisément, la logique de décision d'isolation de défauts utilisée pour le système de calage de la pâle 2 est la suivante :

- Si le résidu $R_{21} = |\beta_{2,m1} - \hat{\beta}_2|$ est proche de zéro et le résidu $R_{22} = |\beta_{2,m2} - \hat{\beta}_2|$ s'écarte de zéro, on conclut que le premier capteur $\beta_{2,m1}$ est en bon état et le deuxième capteur $\beta_{2,m2}$ est défectueux (défaut 2).
- Si le résidu R_{22} est proche de zéro et le résidu R_{21} s'écarte de zéro, on conclut que le deuxième capteur est sain et le premier capteur est défectueux.
- Si les résidus R_{21} et R_{22} sont significativement différents de zéro, on conclut que l'actionneur du système de calage de la pâle 2 est défectueux (défaut 6).

Diagnostic pour le système de calage de la pâle 3 : L'objectif de la procédure de diagnostic appliquée au modèle de calage de la pâle 3 est de détecter et d'isoler en temps voulu deux défauts, un défaut capteur de type valeur fixe, qui affecte le premier capteur d'angle de calage de la pâle 3 ($\beta_{3,m1}$) (défaut 3) et un défaut actionneur causé par une chute de pression de la canalisation principale (défaut 7). Les deux défauts détectables en appliquant la même la logique de décision d'isolation de défauts utilisée pour le système de calage de la pâle 2 présenté précédemment.

3.2.1.4 Méthode de diagnostic pour le système d'entraînement

Dans cette étude, nous avons traité chaque sortie toute seule, car nous avons proposé une procédure de diagnostic en fonction de chaque type de défaut, technique pour le diagnostic de défaut capteur de type valeur fixe affecte l'un des capteurs de vitesse du rotor (défaut 4) et autre technique pour le diagnostic de défaut capteur de type gain affecte l'un des capteurs de vitesse du générateur ou du rotor (défaut 5).

a. Méthode de diagnostic pour défaut de vitesse de rotor : Une des difficultés de conception du technique de diagnostic dans cette partie de système éolien est que la vitesse du rotor ω_r est contrôlée par le couple aérodynamique du rotor τ_r, puisque τ_r est basé sur la vitesse du vent qui est mesurable juste à leur contact avec les éoliennes grâce à l'anémomètre, donc il est difficile d'estimer avec précision τ_r. Pour surmonter ce problème, nous allons utiliser la stratégie suivante :

En supposant que le modèle présenté en (2.25), que l'en reformulant ensuite la matrice d'état $A \in \mathfrak{R}^{3\times3}$ en : $A = \begin{bmatrix} A_{dt1} & A_{dt2} \\ A_{dt3} & A_{dt4} \end{bmatrix}$; Où $A_{dt1} \in \mathfrak{R}^{1\times1}$, $A_{dt2} \in \mathfrak{R}^{1\times2}$, $A_{dt3} \in \mathfrak{R}^{2\times1}$ et $A_{dt4} \in \mathfrak{R}^{2\times2}$.

Alors, nous avons le système suivant :

$$\begin{pmatrix} \dot{\omega}_g(t) \\ \dot{\theta}_\Delta(t) \end{pmatrix} = A_{dt4} \begin{pmatrix} \omega_g(t) \\ \theta_\Delta(t) \end{pmatrix} + B_{dt1}\tau_g(t) + A_{dt3}\omega_r(t) \tag{3.10}$$

Où $B_{dt1} = \begin{bmatrix} -\frac{1}{J_g} & 0 \end{bmatrix}$.

En définissant le vecteur d'état : $z_{dt} = \begin{pmatrix} \omega_g(t) \\ \theta_\Delta(t) \end{pmatrix}$.

Le système (3.10) ci-dessus devient :

$$\begin{aligned} \dot{z}_{dt}(t) &= A_{dt4}z_{dt}(t) + B_{dt1}\tau_g(t) + A_{dt3}\omega_r(t) \\ \omega_g(t) &= C_{dt}z_{dt}(t) \end{aligned} \tag{3.11}$$

Où $C_{dt} = \begin{bmatrix} 1 & 0 \end{bmatrix}$.

Maintenant, les entrées $\omega_r(t)$ et $\tau_g(t)$ sont tous les deux disponibles et la paire (A_{dt4}, C_{dt})

est observable. Notons que le défaut du capteur de vitesse du rotor apparaît dans l'équation précédente en tant que «défaut actionneur» (associé à la vitesse du rotor $\omega_r(t)$). Ensuite, la conception de principe de diagnostic dans le système d'entrainement sera réalisée sur la base de la représentation d'état (3.11) précédente. Le défaut capteur de vitesse du rotor peut être détecté par un schéma de diagnostic basé sur l'équation (3.11) où nous vérifions la cohérence entre les mesures des deux capteurs $\omega_{r,m1}(t)$ et $\omega_{r,m2}(t)$.

Alors, deux estimateurs sont conçus basés sur deux scénarios de panne suivants :

— ***Cas 1*** : Lorsque le deuxième capteur $\omega_{r,m2}(t)$ est défectueux et le premier capteur $\omega_{r,m1}(t)$ est en bonne santé. Ainsi, en utilisant l'équation (3.11), on obtient :

$$\begin{aligned} \dot{z}_{dt}(t) &= A_{dt4} z_{dt}(t) + B_{dt1}\tau_g(t) + A_{dt3}\omega_{r,m1}(t) \\ \omega_g(t) &= C_{dt} z_{dt}(t) \end{aligned} \tag{3.12}$$

Alors, l'estimateur est choisi comme suit :

$$\begin{aligned} \dot{\hat{z}}^1_{dt}(t) &= A_{dt4}\hat{z}^1_{dt}(t) + B_{dt1}\tau_g(t) + A_{dt3}\omega_{r,m1}(t) + L_{dt}(\omega_g(t) - \hat{\omega}^1_g(t)) \\ \hat{\omega}^1_g(t) &= C_{dt}\hat{z}^1_{dt}(t) \end{aligned} \tag{3.13}$$

— ***Cas 2*** : Lorsque le premier capteur $\omega_{r,m1}(t)$ est défectueux et le deuxième capteur $\omega_{r,m2}(t)$ est en bonne santé. Ainsi, en utilisant (3.11), on obtient :

$$\begin{aligned} \dot{z}_{dt}(t) &= A_{dt4} z_{dt}(t) + B_{dt1}\tau_g(t) + A_{dt3}\omega_{r,m2}(t) \\ \omega_g(t) &= C_{dt} z_{dt}(t) \end{aligned} \tag{3.14}$$

Alors, de même l'estimateur est choisi comme suit :

$$\begin{aligned} \dot{\hat{z}}^2_{dt}(t) &= A_{dt4}\hat{z}^2_{dt}(t) + B_{dt1}\tau_g(t) + A_{dt3}\omega_{r,m2}(t) + L_{dt}(\omega_g(t) - \hat{\omega}^2_g(t)) \\ \hat{\omega}^2_g(t) &= C_{dt}\hat{z}^2_{dt}(t) \end{aligned} \tag{3.15}$$

Où L_{dt} est le gain d'observateur choisi pour assurer la stabilité de la matrice $A_{dt4} - L_{dt}C_{dt}$.

Clairement, l'erreur d'estimation de sortie converge à zéro en l'absence de fautes. Alors, en définissant les résidus $R_4 = |\omega_g(t) - \hat{\omega}^1_g(t)|$ et $R_{51} = |\omega_g(t) - \hat{\omega}^2_g(t)|$, le schéma de décision d'isolation est définit comme suit :

— Si R_4 est proche de zéro et que R_{51} s'écarte considérablement de zéro, en conclut que le premier capteur est en bon santé et le deuxième capteur est défectueux.
— Si R_{51} est proche de zéro et que R_4 s'écarte considérablement de zéro, en conclut que le premier capteur est défectueux et le deuxième capteur est en bon santé.

b. Méthode de diagnostic pour défaut de vitesse de générateur : Le défaut du capteur de vitesse du générateur (défaut 5) peut être détecté et isolé à l'aide d'une méthode simple basée sur la dynamique du système donnée dans [**84**]. Plus précisément, dans (2.21) nous avons P_g, η_g, τ_g sont tous mesurés ou connus, une estimation de la vitesse du générateur est donnée par :

$$\hat{\omega}_g(t) = \frac{P_g}{\eta_g \cdot \tau_g} \tag{3.16}$$

Où $\hat{\omega}_g(t)$ est la vitesse estimée du générateur. En comparant $\omega_g(t)$ avec les deux mesures de capteur $\omega_{g,m1}(t)$ et $\omega_{g,m2}(t)$, le défaut du capteur de vitesse du générateur peut être diagnostiqué en utilisant le schéma de décision d'isolement suivant :

— Si $R^1_{52} = |\omega_{g,m1}(t) - \hat{\omega}_g(t)|$ est proche de zéro et que $R^2_{52} = |\omega_{g,m2}(t) - \hat{\omega}_g(t)|$ s'écarte considérablement de zéro, on conclut que le premier capteur est en bonne santé et le deuxième capteur est défectueux.
— Si R^2_{52} est proche de zéro et que R^1_{52} s'écarte considérablement de zéro, en conclut que le deuxième capteur est en bonne santé et le premier capteur est défectueux.
— Si R^1_{52} est proche de zéro et que R^2_{52} est proche de zéro aussi, on conclut que les deux capteurs sont en bonne santé.
— Si R^1_{52} s'écarte considérablement de zéro et que R^2_{52} aussi s'écarte considérablement de zéro, on conclut que les deux capteurs sont défectueux.

3.2.1.5 Méthode de diagnostic pour le modèle de convertisseur

Dans le système de convertisseur (3.2), le défaut de convertisseur (défaut 8) considéré comme un décalage dans la commande de convertisseur interne. D'un point de vue mathématique, il n'y a pas de réalisations d'espace d'états uniques pour une fonction de transfert entrées-sorties données. D'après le modèle d'origine convertisseur et génératrice (2.19), la dynamique du convertisseur est la suivante :

$$\dot{\tau}_g(t) = -\alpha_{gc}\tau_g(t) + \alpha_{gc}\tau_{g,r}(t) + \theta\alpha_{gc}\tau_g(t) \tag{3.17}$$

Où θ est un décalage constant résultant du défaut ($\theta = 0$ dans l'absence du faute).

Alors, l'estimateur est choisi comme suit :

$$\dot{\hat{\tau}}_g(t) = -\alpha_{gc}\tau_g(t) + \alpha_{gc}\tau_{g,r}(t) + \lambda(\hat{\tau}_g(t) - \tau_g(t)) \tag{3.18}$$

Où $\hat{\tau}_g(t)$ est l'estimation de $\tau_g(t)$ et $\lambda > 0$ est un pôle de filtrage.

Clairement, en l'absence de défauts et d'erreur de modélisation et de bruit, l'erreur d'estimation $R_8 = |\hat{\tau}_g(t) - \tau_g(t)|$ converge vers zéro.

Par conséquent, nous pouvons diagnostiquer le modèle de convertisseur en suivant le schéma de décision de panne suivante :

— Si $R_{81} = |\hat{\tau}_g(t) - \tau_{g,m1}(t)|$ proche de zéro et $R_{82} = |\hat{\tau}_g(t) - \tau_{g,m2}(t)|$ s'écarte de manière significative de zéro, le premier capteur est en bon état et le deuxième capteur est défectueux.

— Si R_{82} proche de zéro et R_{81} s'écarte de manière significative de zéro, le deuxième capteur est en bon état et le premier capteur est défectueux.

— Si R_{81} et R_{82} sont tous les deux significativement différents de zéro, alors en conclut que l'actionneur du convertisseur est défectueux.

3.2.1.6 Evaluation des résidus

En se basant sur le type du modèle à diagnostiquer, deux stratégies se posent. Pour les systèmes déterministes, des stratégies d'évaluation de la norme de résidus sont préférées, et dans le cas des systèmes stochastiques, des méthodes statistiques sont adoptées. Divers fonctions d'évaluations sont proposées dans la littérature. Une étude détaillée est proposée par [**85**].

Cependant, dans cette contribution nous avons proposé une technique de seuillage adaptatif de résidus basée sur l'énergie pour l'évaluation résiduelle suivante :

$$J(t) = \|R_i(t)\|_e \tag{3.19}$$

Comme discuté dans [**86**], la fonction d'évaluation résiduelle basée sur l'énergie résiduelle $J(t)$ peut être évaluée en utilisant une longueur de fenêtre temporelle T comme suit :

$$J(t) = \|R_i(t)\|_{e,T} = \|R_i(t)\|_{2,T} = \sqrt{\int_{t-T}^{t} R_i^T(\tau)R_i(\tau)d\tau} \tag{3.20}$$

R_i/F_i	F_1	F_2	F_3	F_4	F_{5r}	F_{5g}	F_6	F_7	F_8
R_1	1	0	0	0	0	0	0	0	0
R_{21}	0	0	0	0	0	0	1	0	0
R_{22}	0	1	0	0	0	0	1	0	0
R_{31}	0	0	1	0	0	0	0	1	0
R_{32}	0	0	0	0	0	0	0	1	0
R_4	0	0	0	1	0	0	0	0	0
R_{51}	0	0	0	0	1	0	0	0	0
${R_{52}}^1$	0	0	0	0	0	0	0	0	0
${R_{52}}^2$	0	0	0	0	0	1	0	0	0
R_{81}	0	0	0	0	0	0	0	0	1
R_{82}	0	0	0	0	0	0	0	0	1

TABLE 3.2 – Table de signature des défauts.

Où $R_i^T(t)$ est le transposé du résidu $R_i(t)$.

Alors, l'évaluation de la décision de détection de défaut repose sur la règle suivante :
— Si $J(t) < J_{th}(t)$ Alors $f(t) = 0$;
— Si $J(t) \geq J_{th}(t)$ Alors $f(t) = 1$.
Où $f(t)$ représente les défauts considérés.

Le seuil adaptatif $J_{th}(t)$ est obtenu comme suit :

$$J_{th}(t) = \sup \frac{1}{2\pi} \int_0^T |R_i^2(t)| dt \tag{3.21}$$

Enfin, dans ce qui suit pour les résultats de simulations obtenus, nous avons seulement transformé les seuils R_i discutés dans les schémas de diagnostic réalisés précédemment (voir tabeau 3.2), dans cette proposition par cette évaluation de résidu par le seuil adaptatif basé sur l'énergie proposé dans toutes les parties du système éolien.

3.2.1.7 Résultats de la simulation

Le contrôleur d'éolienne utilisé dans ce travail dans deux régions est présenté dans la section (2.4.4) dans le chapitre précédent. La région 2 est désignée pour l'optimisation de la puissance, et la région 3 correspond à la saturation. Le contrôleur est mis en œuvre

avec une fréquence d'échantillonnage de 100 Hz. Les figures 2.7 et 3.3 montrent respectivement l'évolution en fonction du temps de la vitesse du vent $\nu_\omega(t)$ (l'entrée) et la puissance électrique générée $P_{g,m}(t)$ (la sortie). Toutes les suivantes simulations sont effectuées pendant une séquence du temps de 4400s.

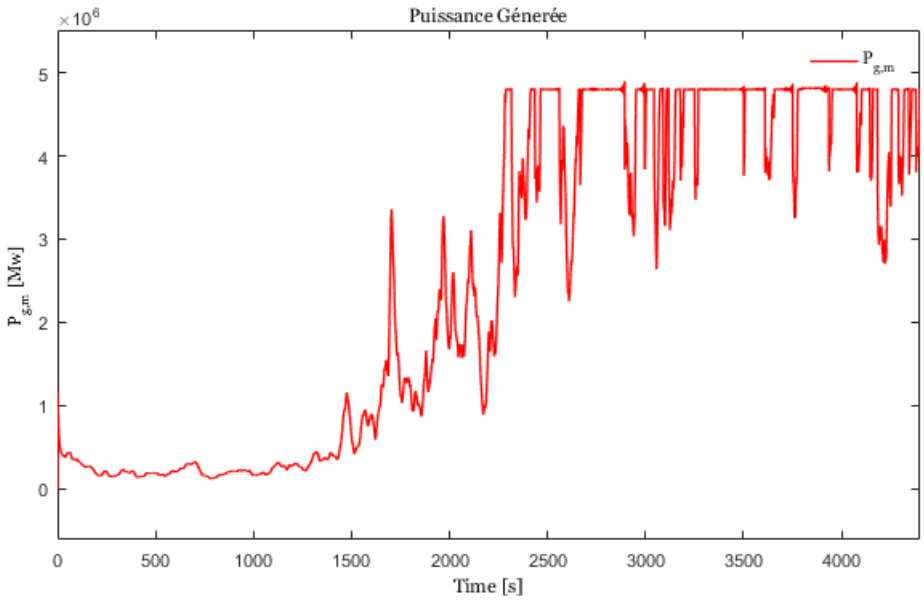


FIGURE 3.3 – Puissance générée $P_{g,m}(t)$.

Étant donné que le système éolien utilisé est composé d'un système à trois actionneurs pour le calage de la pâle, d'un convertisseur et d'un système d'entraînement, en utilisant le processus de génération et d'évaluation résiduelle énergétique détaillé précédemment, par la suite nous avons traité et discuté chaque défaut tout seul :

Défaut 1 : Le défaut 1 est un défaut capteur de type valeur fixe qui affecte le premier capteur d'angle position de calage de la première pâle $\beta_{1,m1}$, ce défaut a été détecté et isolé après seulement une période d'échantillonnage. Cependant, cette décision sur le défaut 1 indique la fin de ce défaut avant deux périodes d'échantillonnage. La figure 3.4 montre le résultat de détection et d'isolation du défaut 1 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 2 : Le défaut 2 est un défaut capteur de type gain qui affecte le deuxième capteur d'angle de position de calage de la deuxième pâle $\beta_{2,m2}$, ce défaut a été détecté et isolé

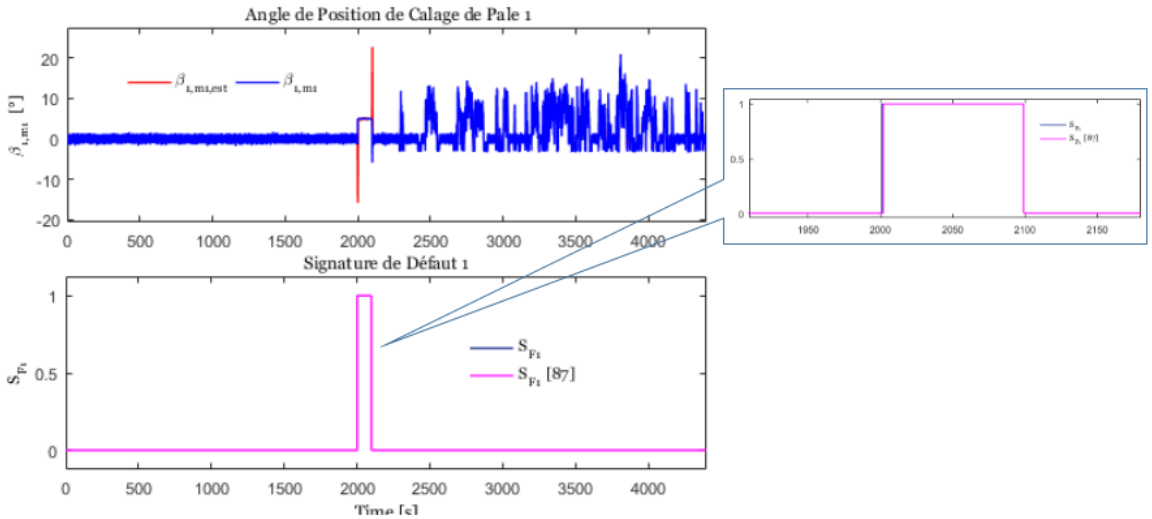


FIGURE 3.4 – Détection et isolation de défaut 1.

après quatre périodes d'échantillonnage. Cependant, cette décision sur le défaut 2 indique la fin de ce défaut avant une période d'échantillonnage. La figure 3.5 montre le résultat de la détection et d'isolation du défaut 2 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 3 : Le défaut 3 est un défaut capteur de type valeur fixe qui affecte le premier capteur d'angle position de calage de la troisième pâle $\beta_{3,m1}$, ce défaut a été détecté et isolé après seulement une période d'échantillonnage. Cependant, cette décision sur le défaut 3 indique la fin de ce défaut avant une seule période d'échantillonnage. La figure 3.6 montre le résultat de la détection et d'isolation du défaut 3 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 4 : Le défaut 4 est un défaut capteur de type valeur fixe qui affecte le premier capteur de vitesse du rotor $\omega_{r,m1}$, ce défaut a été détecté et isolé après seulement une période d'échantillonnage. Cependant, cette décision sur le défaut 4 indique la fin de ce défaut avant une période d'échantillonnage. La figure 3.7 montre le résultat de la détection et de l'isolation du défaut 4 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 5 : Le défaut 5 est un défaut capteur de type gain qui affecte les capteurs de vitesse du rotor $\omega_{r,m2}$ et du générateur $\omega_{g,m2}$. Ce défaut a été détecté et isolé après cinq périodes d'échantillonnage. Cependant, cette décision sur le défaut 5 indique la fin de ce

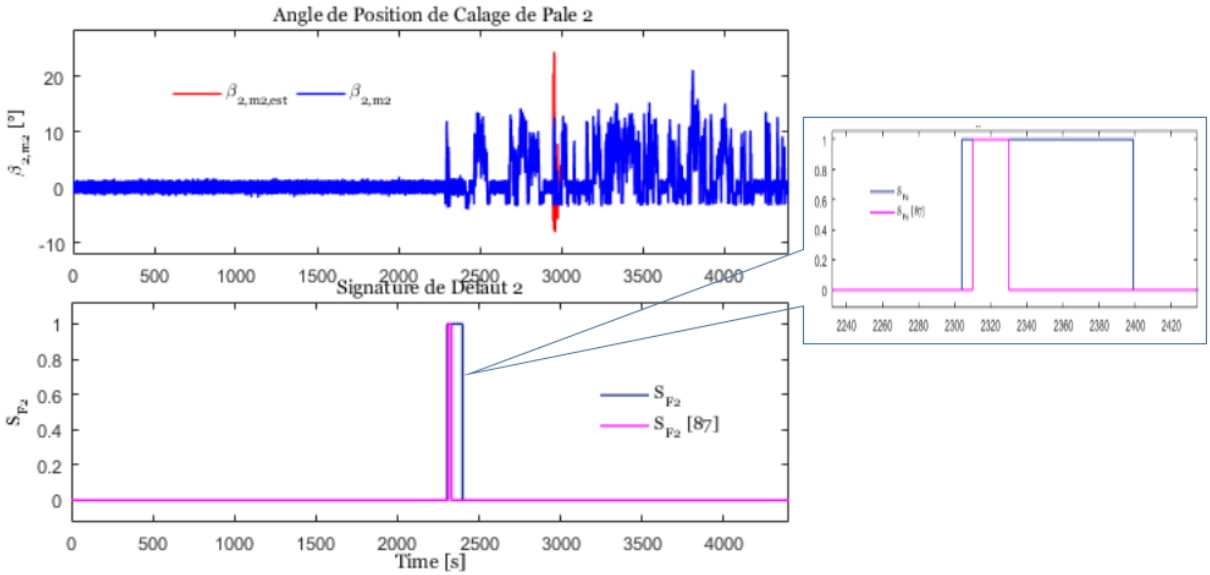


FIGURE 3.5 – Détection et isolation de défaut 2.

défaut avant quatre périodes d'échantillonnage. Les figures 3.8 et 3.9 montrent respectivement le résultat de la détection et de l'isolation du défaut 5 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 6 : Le défaut 6 est un défaut actionneur qui affecte le deuxième pâle, il a causé par une forte teneur en air dans l'huile. Ce défaut a été détecté et isolé après dix périodes d'échantillonnage. Cependant, cette décision sur le défaut 6 indique la fin de ce défaut avant six périodes d'échantillonnage. La figure 3.10 montre le résultat de la détection et de l'isolation du défaut 6 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 7 : Le défaut 7 est un défaut actionneur qui affecte le troisième pâle, il a provoqué par une chute de pression de la canalisation principale. Ce défaut a été détecté et isolé après neuf périodes d'échantillonnage. Cependant, cette décision sur le défaut 7 indique la fin de ce défaut avant sept périodes d'échantillonnage. La figure 3.11 montre le résultat de la détection et de l'isolation du défaut 7 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

Défaut 8 : Le défaut 8 est un défaut affectant le convertisseur, il représente un décalage dans les boucles de commande du convertisseur interne. Ce défaut a été détecté et isolé

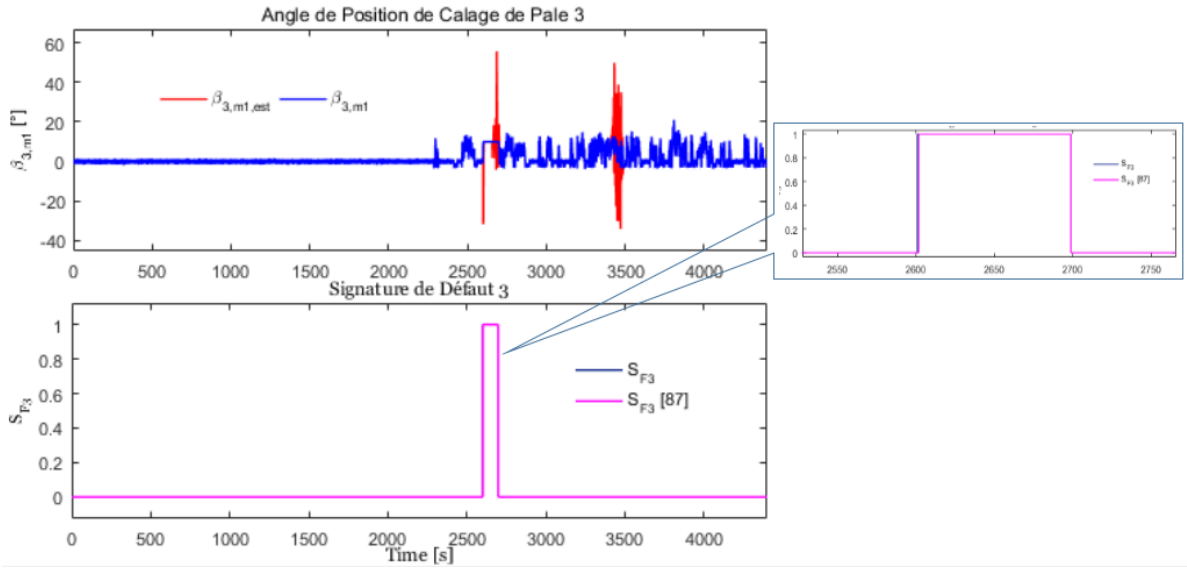


FIGURE 3.6 – Détection et isolation de défaut 3.

après quatorze périodes d'échantillonnage. Cependant, cette décision sur le défaut 8 indique la fin de ce défaut avant onze périodes d'échantillonnage. La figure 3.12 montre le résultat de la détection et de l'isolation du défaut 8 par la technique proposée, la comparaison de ce résultat avec le travail présenté dans [**87**] permet d'évaluer l'efficacité de notre proposition.

3.2.2 Le diagnostic du système éolien basé sur l'observateur proportionnel multi-intégrales (OPMI)

3.2.2.1 Modèle flou du système éolien

Dans la littérature, nous pouvons dénombrer de nombreux types de modèles flous. Cependant on peut distinguer deux classes principales de modèles flous : le modèle flou de Mamdani et le modèle flou de T-S. La principale différence entre ces deux modèles réside dans la partie conséquence. Le modèle flou de Mamdani utilise des sous-ensembles flous dans la partie conséquence alors que le modèle flou de T-S utilise des fonctions (linéaires ou non linéaires) des variables mesurables. Dans le modèle T-S, la partie conséquence est un modèle linéaire (représentation d'état, modèle autorégressif). Afin d'exploiter la théorie très riche des modèles LTI, le modèle de T-S dont la partie conséquence est un modèle linéaire en représentation d'état est de loin le plus utilisé en analyse et commande [**88**].

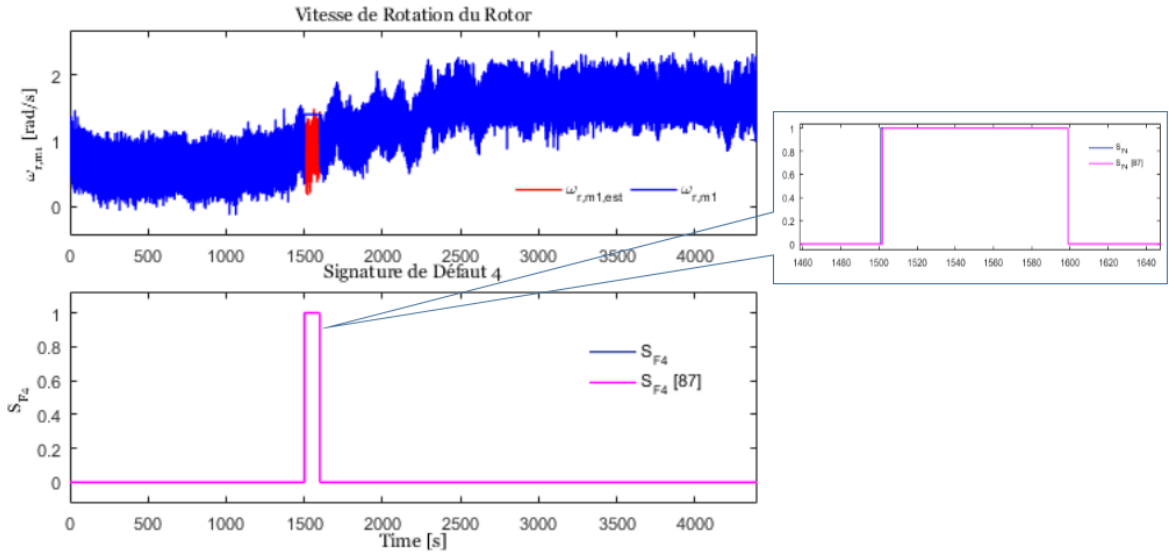


FIGURE 3.7 – Détection et isolation de défaut 4.

L'approche globale basé sur le modèle multiple LTI (linéaires ou affines) autour de différents points de fonctionnement a été élaborée ces dernières années [**89**]. L'interpolation de ces modèles locaux à l'aide de fonctions d'activation normalisées permet de modéliser le système global non linéaire. Cette approche, dite multimodèles, s'inspire des modèles flous du type Takagi-Sugeno (T-S) [**90**]. En effet, un multimodèle réalise une partition floue de l'espace caractéristique dit aussi espace de décision, c'est l'espace caractérisé par l'ensemble des variables caractéristiques (de décision) qui peuvent être des variables d'état mesurables et/ou la commande. Les zones de fonctionnement sont définies en termes de propositions sur les variables de prémisse.

On propose dans cette étude, un modèle d'éolienne basé sur les vecteurs d'états et d'entrée suivantes :

$$x(t) = \begin{pmatrix} \omega_r(t) & \omega_g(t) & \theta_\Delta(t) & \tau_g(t) & \beta_1(t) & \dot{\beta}_1(t) & \beta_2(t) & \dot{\beta}_2(t) & \beta_3(t) & \dot{\beta}_3(t) \end{pmatrix}^T \tag{3.22}$$

$$u(t) = \begin{pmatrix} \tau_{g,ref}(t) & \beta_{1,ref}(t) & \beta_{2,ref}(t) & \beta_{3,ref}(t) \end{pmatrix}^T \tag{3.23}$$

Le modèle de l'éolienne peut être réécrit comme suit, lorsqu'on arrange les équations (2.22), (2.23), (2.24), (2.20) et (3.1) pour chaque pâle, avec les termes non linéaires sont présentés par les paramètres $z_i(t)$:

$$\dot{x}(t) = A \cdot x(t) + B \cdot u(t) \tag{3.24}$$

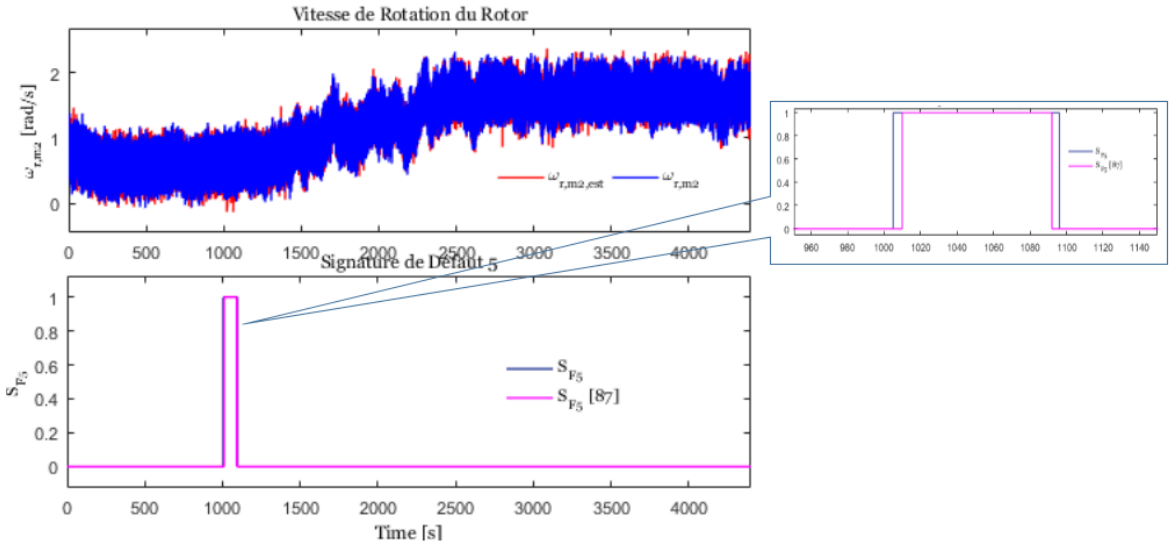


FIGURE 3.8 – Détection et isolation de défaut 5 dans le rotor.

$$y(t) = C \cdot x(t) \tag{3.25}$$

Avec $x(t) \in \mathfrak{R}^n$ représente le vecteur d'état, $u(t) \in \mathfrak{R}^m$ est le vecteur d'entrée, $y(t) \in \mathfrak{R}^l$ est le vecteur de sortie, $A \in \mathfrak{R}^{n \times n}$ est la matrice d'état, $B \in \mathfrak{R}^{n \times m}$ est la matrice d'entrée et $C \in \mathfrak{R}^{l \times n}$ est la matrice de sortie.

$$\text{Où } B = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ \frac{1}{t_g} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & w_n^2 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & w_n^2 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & w_n^2 \end{bmatrix}, C = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \text{ et}$$

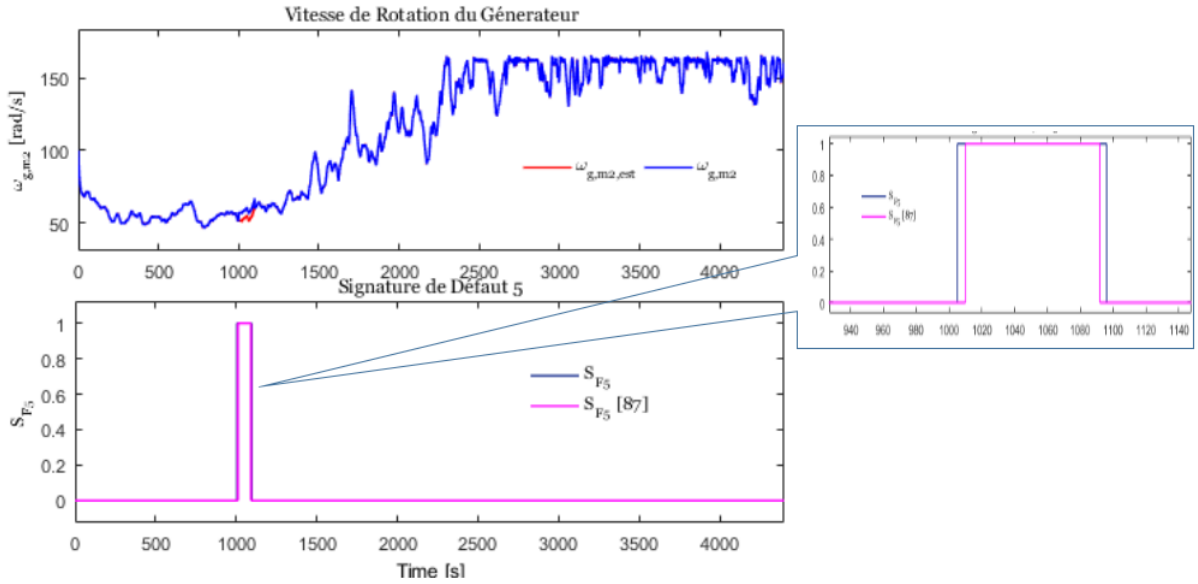


FIGURE 3.9 – Détection et isolation de défaut 5 dans le génerateur.

$$A = \begin{bmatrix} \frac{B_{dt}+B_r}{J_r} & \frac{B_{dt}}{N_g J_r} & \frac{K_{dt}}{J_r} & 0 & z_1(t) & 0 & z_2(t) & 0 & z_3(t) & 0 \\ -\frac{\eta_{dt}K_{dt}}{N_g J_g} & \frac{\eta_{dt}B_{dt}}{J_g N_g^2}+\frac{B_g}{J_g} & \frac{\eta_{dt}K_{dt}}{N_g J_g} & -\frac{1}{J_g} & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & -\frac{1}{N_g} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -\frac{1}{t_g} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -w_n^2 & -2\zeta w_n & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -w_n^2 & -2\zeta w_n & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -w_n^2 & -2\zeta w_n \end{bmatrix}.$$

Et :

$$z_1(t) = \frac{\rho \cdot \pi \cdot R^3 \cdot C_q(\lambda_1(t), \beta_1(t)) \cdot \nu_{w,1}(t)^2}{6 \cdot J_r \cdot \beta_1(t)} \tag{3.26}$$

$$z_2(t) = \frac{\rho \cdot \pi \cdot R^3 \cdot C_q(\lambda_2(t), \beta_2(t)) \cdot \nu_{w,2}(t)^2}{6 \cdot J_r \cdot \beta_2(t)} \tag{3.27}$$

$$z_3(t) = \frac{\rho \cdot \pi \cdot R^3 \cdot C_q(\lambda_3(t), \beta_3(t)) \cdot \nu_{w,3}(t)^2}{6 \cdot J_r \cdot \beta_3(t)} \tag{3.28}$$

Remarque 3.1 : La structure non linéaire du système éolien présentée par les équations (3.24) et (3.25), la non-linéarité dans cette structure est présentée par les termes "$z_i(t)$" (définit par les Eqs (3.26), (3.27) et (3.28)), cette non-linéarité est présentée en coefficient

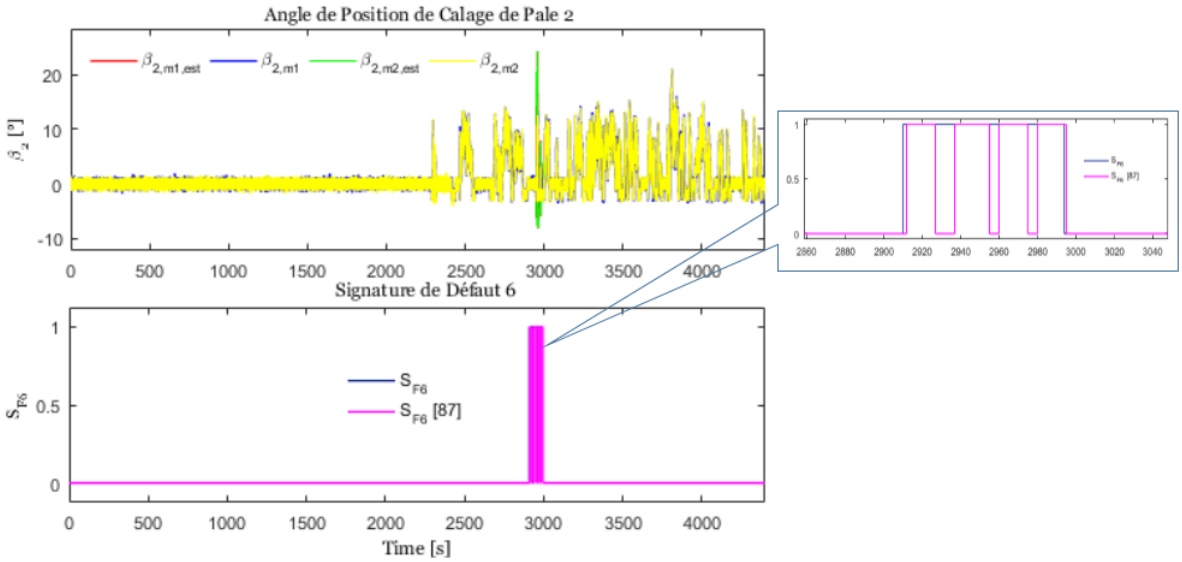


FIGURE 3.10 – Détection et isolation de défaut 6.

de puissance $C_q(\lambda_i, \beta_i)$ et en vitesse du vent $\nu_{\omega,i}(t)$ pour chaque pâle. Pour cette raison, dans la section suivante nous avons utilisé la technique de Takagi-Sugeno pour résoudre ce problème de non-linéarité.

Le modèle flou Takagi et Sugeno (TS) [**91**] est décrit par des règles "Si-Alors" qui représentent dans l'approche multimodèle, qui est une approche mathématique visant à représenter du mieux possible le fonctionnement dynamique de processus, en utilisant des modèles linéaires invariants dans le temps (LTI). Cette approximation permet ainsi d'étudier le système éolien qui ayant ce comportement non linéaire en le représentant par un seul modèle linéaire (linéarisé tangent autour d'un point d'équilibre) [**92**].

Tout modèle flou du type TS utilise des règles comme :

Règle i :

$$Si : \ z_1(t) \ est \ M_{i1}, \ z_2(t) \ est \ M_{i2} \ et \ z_3(t) \ est \ M_{i3}$$

$$Alors : \begin{cases} \dot{x}(t) = A_i \cdot x(t) + B \cdot u(t) \\ \\ y(t) = C \cdot x(t) \end{cases} \tag{3.29}$$

Où $i = 1, 2, ..., r$ avec $r = 2^3$ est le nombre des régles, M_{ij} sont les fonctions d'appartenance des ensembles flous, $A_i \in \mathfrak{R}^{n \times n}$.

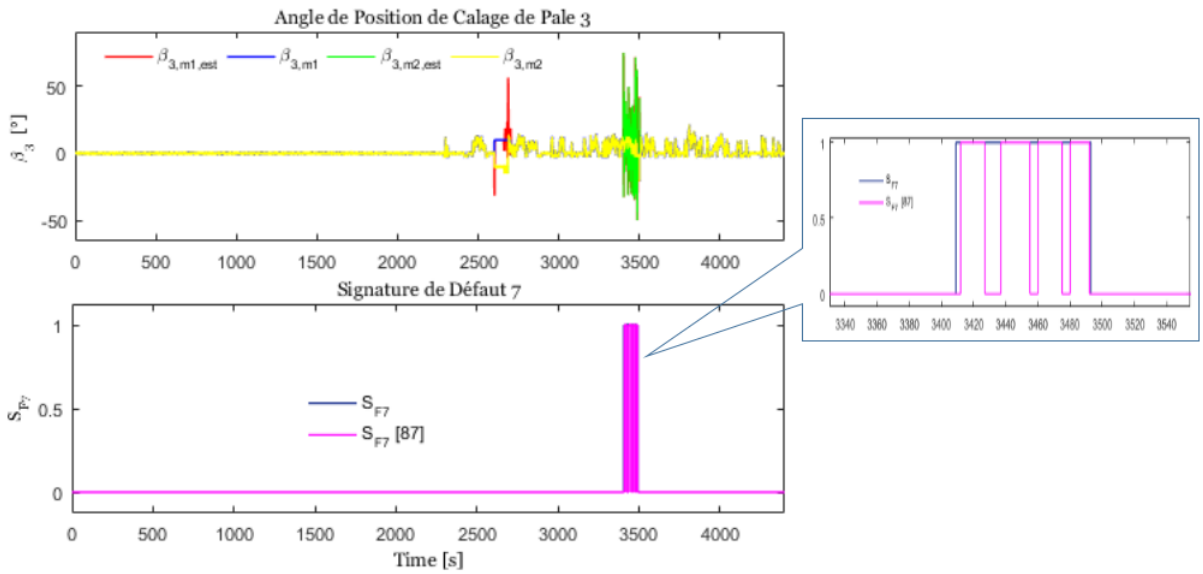


FIGURE 3.11 – Détection et isolation de défaut 7.

$z_1(t)$, $z_2(t)$ et $z_3(t)$ sont des variables connues pouvant être des fonctions des variables d'état, et/ou des perturbations externes en fonction du temps. À chaque règle est attribué un poids $\omega_i(z(t))$ qui dépend du vecteur $z(t) = [z_1(t), z_2(t), z_3(t)]$ et du choix de l'opérateur logique utilisé (”et” ou bien ”ou”).

L'opérateur ”et” utilisé dans cette étude est souvent choisi comme étant un produit, d'où :

$$\omega_i(z(t)) = \prod_{j=1}^{p} M_{ij}(z_j(t)) \tag{3.30}$$

avec $j = 1, ..., p$ où (p=3) et $\omega_i(z(t)) \geq 0$ pour tout $t \geq 0$

Le modèle flou global du système éolien est représenté par :

$$\dot{x}(t) = \frac{\sum_{i=1}^{M} \omega_i(z(t))(A_i x(t) + Bu(t))}{\sum_{i=1}^{M} \omega_i(z(t))} \tag{3.31}$$

qui peut être réécrit comme :

$$\dot{x}(t) = \sum_{i=1}^{M} \mu_i(z(t))(A_i x(t) + Bu(t)) \tag{3.32}$$

où

$$\mu_i(z(t)) = \frac{\omega_i(z(t))}{\sum_{i=1}^{M} \omega_i(z(t))} \tag{3.33}$$

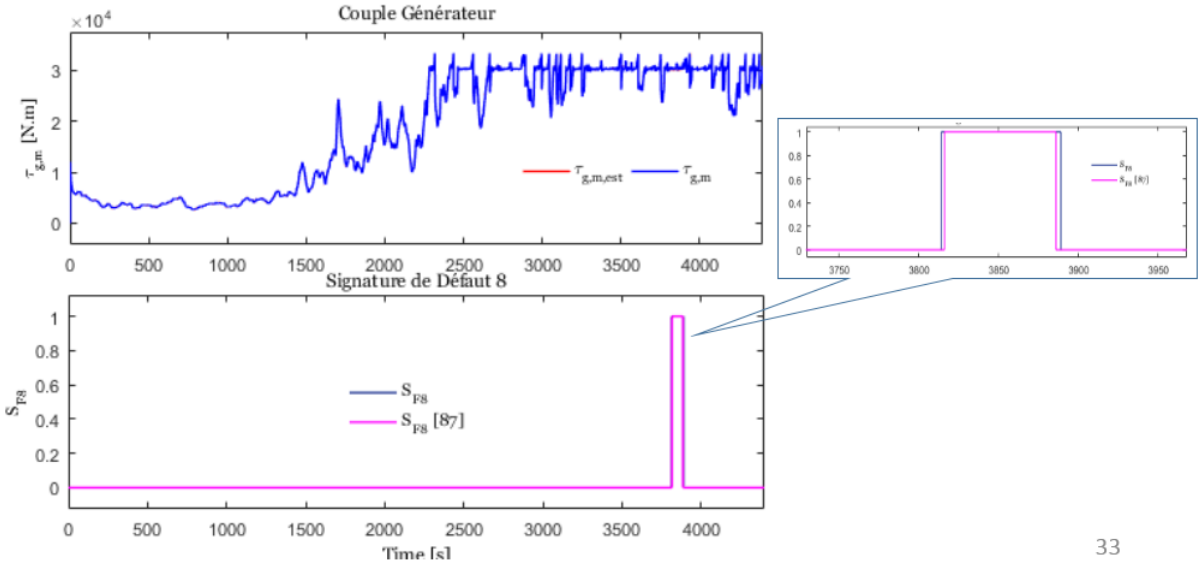


FIGURE 3.12 – Détection et isolation de défaut 8.

La fonction $\mu_i(z(t))$ dite fonction d'activation détermine le degré d'activation du ième modèle local associé. Selon la zone où évolue le système, cette fonction indique la contribution plus ou moins importante du modèle local correspondant dans le modèle global, elle assure un passage progressif de ce modèle aux modèles locaux voisins. Ces fonctions dépendent généralement du vecteur d'état $x(t)$, qui peuvent être de forme triangulaire, sigmoïdale ou gaussienne, et satisfont les propriétés de convexité suivantes :

$$\begin{cases} \sum_{i=1}^{M} \mu_i(x(t)) = 1 \\ \\ 0 \leq \mu_i(x(t)) \leq 1 \end{cases} \tag{3.34}$$

Nous évaluons ensuite les valeurs minimales et maximales des $z_i(t)$:
$\min(z_1(t)) = z_{1,min}$, $\max(z_1(t)) = z_{1,max}$, $\min(z_2(t)) = z_{2,min}$, $\max(z_2(t)) = z_{2,max}$, $\min(z_3(t)) = z_{3,min}$, $\max(z_3(t)) = z_{3,max}$.

À partir des valeurs maximales et minimales des $z_i(t)$, les $z_i(t)$ peuvent être représentés par :

$$z_1(x(t)) = M_{11}(x(t)) \cdot z_{1,max} + M_{12}(x(t)) \cdot z_{1,min} \tag{3.35}$$

$$z_2(x(t)) = M_{21}(x(t)) \cdot z_{2,max} + M_{22}(x(t)) \cdot z_{2,min} \tag{3.36}$$

$$z_3(x(t)) = M_{31}(x(t)) \cdot z_{3,max} + M_{32}(x(t)) \cdot z_{3,min} \tag{3.37}$$

Règle	$z_1(t)$	$z_2(t)$	$z_3(t)$	A_i
Règle 1	$z_{1,min}$	$z_{2,min}$	$z_{3,min}$	A_1
Règle 2	$z_{1,max}$	$z_{2,min}$	$z_{3,min}$	A_2
Règle 3	$z_{1,min}$	$z_{2,max}$	$z_{3,min}$	A_3
Règle 4	$z_{1,max}$	$z_{2,max}$	$z_{3,min}$	A_4
Règle 5	$z_{1,min}$	$z_{2,min}$	$z_{3,max}$	A_5
Règle 6	$z_{1,max}$	$z_{2,min}$	$z_{3,max}$	A_6
Règle 7	$z_{1,min}$	$z_{2,max}$	$z_{3,max}$	A_7
Règle 8	$z_{1,max}$	$z_{2,max}$	$z_{3,max}$	A_8

TABLE 3.3 – Le vecteur d'état pour chaque modèle local.

Avec, les fonctions d'appartenance ont été calculées pour chaque terme non linéaire comme suit :

$$\begin{cases} M_{11}(x(t)) = \frac{z_1(t)-z_{1,min}}{z_{1,max}-z_{1,min}} \\ M_{12}(x(t)) = \frac{z_{1,max}-z_1(t)}{z_{1,max}-z_{1,min}} \end{cases} \tag{3.38}$$

$$\begin{cases} M_{21}(x(t)) = \frac{z_2(t)-z_{2,min}}{z_{2,max}-z_{2,min}} \\ M_{22}(x(t)) = \frac{z_{2,max}-z_2(t)}{z_{2,max}-z_{2,min}} \end{cases} \tag{3.39}$$

$$\begin{cases} M_{31}(x(t)) = \frac{z_3(t)-z_{3,min}}{z_{3,max}-z_{3,min}} \\ M_{32}(x(t)) = \frac{z_{3,max}-z_3(t)}{z_{3,max}-z_{3,min}} \end{cases} \tag{3.40}$$

Alors, on aboutit huit modèles locaux par la combinaison des fonctions M_{11}, M_{12}, M_{21}, M_{22}, M_{31} et M_{32}.

Les régles sont spécifiées comme indiqué dans le tableau (3.3), basé sur les bornes des termes non linéaires $z_{i,max}$ et $z_{i,min}$.

3.2.2.2 Conception du contrôleur flou

Dans le cas de multimodèle du type T-S, cette technique de synthèse de régulateurs correspond à la méthode PDC [**93**]. Elle suppose que tous les sous modèles linéaires soient au moins stabilisables. Dans toute la suite, on les supposera commandables.

Soit le modèle T-S continu donné par l'équation (3.32), une loi de commande issue d'une synthèse PDC sera donc la combinaison de lois pour chaque sous-modèle, de la forme :

Règle de contrôleur i :

$$\textbf{Si}: \ z_1(t)\, est\, M_{i1},\ z_2(t)\, est\, M_{i2}\, et\, z_3(t)\, est\, M_{i3}\ \textbf{Alors}: \ u(t) = -T_i \cdot x(t) \tag{3.41}$$

Où $i = 1, 2, ..., 8$ et Ti sont les gains de contrôleur par retour d'état pour chacun modèle local.

Le contrôleur flou global est représenté par :

$$u(t) = -\frac{\sum_{i=1}^{M} \omega_i(z(t))(T_i x(t))}{\sum_{i=1}^{M} \omega_i(z(t))} \tag{3.42}$$

qui peut être réécrit comme :

$$u(t) = -\sum_{i=1}^{M} \mu_i(z(t))(T_i x(t)) \tag{3.43}$$

Théorème 3.1 [94] : Les conditions de stabilité du système en boucle fermée reviennent à chercher les gains de commande T_i tels que la dérivée d'une fonction candidate quadratique de Lyapunov soit négative. Stabiliser le problème de stabilisation par la région LMI $S(\alpha, r, \theta)$ a une solution si et seulement s'il existe une matrice définie positive symétrique X_i et une matrice Y_i satisfaisant :

$$A_i X_i + B Y_i + X_i A_i^T + Y_i^T B^T + 2\alpha X_i < 0 \tag{3.44}$$

$$\begin{bmatrix} -rX_i & qX_i + A_i X_i + B Y_i \\ qX_i + X_i A_i^T + Y_i^T B^T & -rX_i \end{bmatrix} < 0 \tag{3.45}$$

$$\begin{bmatrix} (A_i X_i + B Y_i + X_i A_i^T + Y_i^T B^T)\sin\theta & (A_i X_i + B Y_i - (X_i A_i^T + Y_i^T B^T))\cos\theta \\ (A_i X_i + B Y_i - (X_i A_i^T + Y_i^T B^T))\cos\theta & (A_i X_i + B Y_i + X_i A_i^T + Y_i^T B^T)\sin\theta \end{bmatrix} < 0 \tag{3.46}$$

Avec la solution de notre problème est calculée par :

$$T_i = Y_i X_i^{-1} \tag{3.47}$$

Où α est la vitesse de réponse minimale, r la vitesse de réponse maximale et θ le dépassement. La région d'LMI $S(\alpha, r, \theta)$ est représenté sur la figure 3.13.

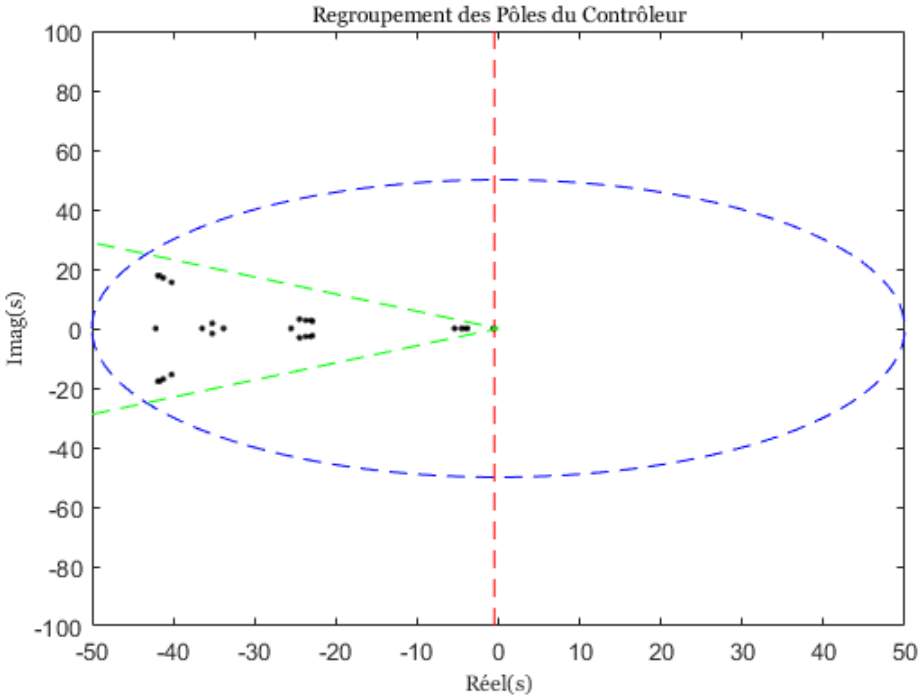


FIGURE 3.13 – Pôles situés dans la région d'LMI $S(\alpha, r, \theta)$.

Remarque 3.2 : Tous les pôles sont en effet situés dans la région d'LMI $S(\alpha, r, \theta)$ ce qui montre que le contrôleur proposé assure la stabilité du système (3.32) (voir Figure 3.13).

3.2.2.3 Conception d'observateur du type Proportionnel Multi-Intégral (PMI)

Le problème qui se pose maintenant est la synthèse d'un observateur PMI du système linéaire à entrées inconnues. Ce problème est assez général et peut concerner deux situations assez différentes. La première est celle où un système est effectivement affecté d'entrées inconnues perturbant son fonctionnement, dont il convient alors d'évaluer l'amplitude afin de concevoir une stratégie de commande compensatrice. La deuxième situation est propre au diagnostic de fonctionnement et plus précisément à l'estimation de défauts d'actionneurs et de capteurs ; dans ce cas, une entrée connue peut être estimée en la considérant comme inconnue afin d'analyser l'erreur d'estimation de cette entrée qui peut être révélatrice

d'un défaut d'actionneur ou bien d'un défaut capteur. Dans la suite, on considère des observateurs du type Proportionel Multi-Integral (PMI) permettant de reconstruire l'état et les entrées inconnues du système éolien.

Apartir des équations. (3.24) et (3.32), le modèle flou TS d'éolienne peut être réécrit avec les variables non mesurables soumises à des défauts et qui affectent à la fois les actionneurs et les capteurs du système et le bruit comme suit :

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{8} \mu_i(z(t))(A_i \cdot x(t) + B \cdot u(t) + F_i \cdot f_a(t) + R \cdot \omega(t)) \\ \\ y(t) = C \cdot x(t) + F \cdot f_s(t) + H \cdot \omega(t) \end{cases} \tag{3.48}$$

Où $x(t) \in \Re^n$ représente le vecteur d'état, $u(t) \in \Re^m$ représente le vecteur d'entrée, $y(t) \in \Re^l$ représente le vecteur de sortie, $f_a(t) \in \Re^{n_{fa}}$ et $f_s(t) \in \Re^{n_{fs}}$ représentent respectivement les défauts actionneurs et capteurs, $\omega(t) \in \Re^{n_\omega}$ représente le vecteur de bruit de mesure, $A_i \in \Re^{n \times n}$ sont les matrices d'état, $B \in \Re^{n \times m}$ est la matrice d'entrée, $C \in \Re^{l \times n}$ est la matrice de sortie, $F_i \in \Re^{n \times n_{fa}}$ sont les matrices de défauts actionneurs, $F \in \Re^{l \times n_{fs}}$ est la matrice de défauts capteurs et $R \in \Re^{n \times n_\omega}$ et $H \in \Re^{l \times n_\omega}$ sont les matrices de perturbations.

Hypothèse 3.1 : Les défauts sont supposés être des signaux variant dans le temps et dont la kième dérivée dans le temps est limitée par la borne f_0, ces défauts proposés sont représentés par les notations suivantes :

$$\begin{cases} \dot{f}(t) = f_1(t) \\ \dot{f}_1(t) = f_2(t) \\ \vdots \\ \dot{f}_{k-1}(t) = f_k(t) \\ f_k(t) \leq f_0 \end{cases} \tag{3.49}$$

Remarque 3.3 : Cette hypothèse permet de prendre en compte une large gamme de défauts actionneurs et capteurs [**95**].

Alors pour estimer simultanément les défauts actionneurs et capteurs, le système (3.48) est transformé en un état augmenté à l'aide du nouvel état exprimé par $f(t)$ et qui représente à la fois les défauts actionneurs et capteurs du système, qui est défini par : $f(t) = \begin{bmatrix} f_a(t) \\ f_s(t) \end{bmatrix}$. Où $f(t) \in \Re^{n_f}$ et $n_f = n_{f_a} + n_{f_s}$.

Ce système augmenté peut être représenté comme suit :

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{8} \mu_i(z(t))(A_i \cdot x(t) + B \cdot u(t) + \bar{F}_i \cdot f(t) + R \cdot \omega(t)) \\ \\ y(t) = C \cdot x(t) + \bar{F} \cdot f(t) + H \cdot \omega(t) \end{cases} \tag{3.50}$$

Avec $\bar{F}_i = \begin{bmatrix} F_i \\ 0 \end{bmatrix}$ et $\bar{F} = \begin{bmatrix} 0 \\ F \end{bmatrix}$.

Le système donné par (3.50) peut alors être décrit comme suit :

$$\begin{cases} \dot{x}_a(t) = \sum_{i=1}^{8} \mu_i(z(t))(\tilde{A}_i \cdot x_a(t) + \tilde{B} \cdot u_a(t) + \tilde{R} \cdot \omega_a(t)) \\ \\ y(t) = \tilde{C} \cdot x_a(t) + \tilde{H} \cdot \omega_a(t) \end{cases} \tag{3.51}$$

Où $\tilde{A}_i = \begin{bmatrix} A_i & \bar{F}_i & 0 & \cdots & 0 & 0 \\ 0 & 0 & I_{n_f} & \cdots & 0 & 0 \\ 0 & 0 & 0 & \ddots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & I_{n_f} \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$, $x_a(t) = \begin{pmatrix} x(t) \\ f(t) \\ f_1(t) \\ f_2(t) \\ \vdots \\ f_{k-1}(t) \end{pmatrix}$, $\tilde{B} = \begin{bmatrix} B \\ 0 \\ \vdots \\ 0 \end{bmatrix}$, $u_a(t) = \begin{pmatrix} u(t) \\ 0 \\ \vdots \\ 0 \end{pmatrix}$,

$\tilde{H} = \begin{bmatrix} H \\ 0 \\ \vdots \\ 0 \end{bmatrix}$, $\tilde{R} = \begin{bmatrix} R \\ 0 \\ \vdots \\ 0 \end{bmatrix}$, $\omega_a(t) = \begin{pmatrix} \omega(t) \\ 0 \\ \vdots \\ 0 \end{pmatrix}$ et $\tilde{C} = \begin{bmatrix} C & \bar{F} & 0 & \cdots & 0 \end{bmatrix}$.

L'observateur (PMI) proposé considéré fournit simultanément les états et les défauts actionneurs et capteurs en présence des variables non mesurables présentées pour le système (3.50) [**96**], cet observateur est décrit par :

$$\begin{cases} \dot{\hat{x}}(t) = \sum_{i=1}^{8} \mu_i(z(t))(A_i \cdot \hat{x}(t) + B \cdot u(t) + \bar{F}_i \cdot \hat{f}(t) + L_{P_i} \cdot (y(t) - \hat{y}(t)) \\ \\ \hat{y}(t) = C \cdot \hat{x}(t) + \bar{F} \cdot \hat{f}(t) \end{cases} \tag{3.52}$$

Où $\hat{f}(t)$ est obtenu par l'observateur PMI proposé à partir de la formule :

$$\begin{cases} \dot{\hat{f}}_j(t) = \sum_{i=1}^{8} \mu_i(z(t))(\hat{f}_{j+1}(t) + L_{I_i} \cdot (y(t) - \hat{y}(t))) \quad j = 1, ..., k-1 \\ \\ \dot{\hat{f}}(t) = \sum_{i=1}^{8} \mu_i(z(t))(\hat{f}_1(t) + L_{I_i} \cdot (y(t) - \hat{y}(t))) \end{cases} \tag{3.53}$$

Pour le système augmenté présenté dans (3.51), l'observateur (3.52) devient :

$$\begin{cases} \dot{\hat{x}}_a(t) = \sum_{i=1}^{8} \mu_i(z(t))(\tilde{A}_i \cdot \hat{x}_a(t) + \tilde{B} \cdot u_a(t) + \tilde{L}_i \cdot (y(t) - \hat{y}(t))) \\ \\ \hat{y}(t) = \tilde{C} \cdot \hat{x}_a(t) \end{cases} \tag{3.54}$$

Où $\tilde{L}_i = \left[\begin{array}{ccccccc} {L_{P_i}}^T & {L_{I_i}}^T & {L_{I_i}}^{1^T} & \cdots & {L_{I_i}}^{k-2^T} & {L_{I_i}}^{k-1^T} \end{array} \right]^T$.

L'erreur d'estimation des variables d'état et défauts et de leurs dérivées est indiquée par $e_a(t) = x_a(t) - \hat{x}_a(t)$. En fait la différence entre le système (3.51) et l'observateur (3.54), donne la dynamique d'erreur d'estimation suivante :

$$\dot{e}_a(t) = \sum_{i=1}^{8} \mu_i(z(t))((\tilde{A}_i - \tilde{L}_i\tilde{C}) \cdot e_a(t) + (\tilde{R} - \tilde{L}_i\tilde{H}) \cdot \omega_a(t)) \tag{3.55}$$

L'objectif est de synthétiser les gains de l'observateur $\tilde{L}_i$ afin d'assurer la stabilité du système (3.55) générant l'erreur d'estimation et de garantir un taux d'atténuation γ des perturbations transférant $\omega_a(t)$ par apport à l'erreur $e_a(t)$. Ce résultat est traduit par les contraintes suivantes :

$$\begin{cases} \lim_{t \to +\infty} e_a(t) = 0 \quad ; \quad \omega_a(t) = 0 \quad ; \quad t \geq 0 \\ \\ \frac{\|e_a(t)\|_2}{\|\omega_a(t)\|_2} < \gamma \qquad ; \quad \omega_a(t) \neq 0 \quad ; \quad t \geq 0 \end{cases} \tag{3.56}$$

Théorème 3.2 : Le système (3.55) est asymptotiquement stable et la performance en L_2 est garanti avec un niveau d'atténuation $\gamma > 0$, s'il existe une matrice $P = P^T > 0$, avec $P \in \Re^{n+kn_f \times n+kn_f}$, et la matrice $\tilde{K}_i \in \Re^{n+kn_f \times n_f}$ telle que pour tout $i = 1, ..., 8$,

satisfaisant le problème d'inégalité (LMI) suivant :

$$\begin{bmatrix} \tilde{A}_i^T P + P\tilde{A}_i - \tilde{K}_i\tilde{C} - \tilde{C}^T\tilde{K}_i^T + I & P\tilde{R}_i - \tilde{K}_i\tilde{H} \\ \tilde{R}_i^T P - \tilde{H}^T\tilde{K}_i^T & -\gamma^2 I \end{bmatrix} < 0 \tag{3.57}$$

Par conséquent, les gains d'observateur PMI proposé sont calculés par l'équation suivantte :

$$\tilde{L}_i = P^{-1}\tilde{K}_i \tag{3.58}$$

Preuve 3.1 : Considérant la fonction quadratique de Lyapunov suivante :

$$V(e_a(t)) = e_a^T(t) \cdot P \cdot e_a(t) \quad , P = P^T > 0 \tag{3.59}$$

La dérivée temporelle (la dynamique) de la fonction quadratique de Lyapunov (3.59) est comme suite :

$$\dot{V}(e_a(t)) = \dot{e}_a^T(t) \cdot P \cdot e_a(t) + e_a^T(t) \cdot P \cdot \dot{e}_a(t) \tag{3.60}$$

En remplaçant Eq (3.55) dans (3.60), la dérivée temporelle de la fonction quadratique de Lyapunov devient :

$$\begin{aligned} \dot{V}(e_a(t)) = \textstyle\sum_{i=1}^{8} \mu_i(z(t))(e_a^T(t)(\tilde{A}_i^T P + P\tilde{A}_i - \tilde{K}_i\tilde{C} - \tilde{C}\tilde{K}_i^T)e_a(t) \\ +\omega_a^T(t)(\tilde{R}_i^T P - \tilde{H}^T\tilde{K}_i^T)e_a(t) + e_a^T(t)(P\tilde{R}_i - \tilde{K}_i\tilde{H})\omega_a(t)) \end{aligned} \tag{3.61}$$

L'objectif est d'atténuer l'effet de la perturbation $\omega_a(t)$ sur l'erreur $e_a(t)$:

$$\frac{\|e_a(t)\|_2}{\|\omega_a(t)\|_2} < \gamma \quad ; \quad \|\omega_a(t)\|_2 \neq 0 \quad ; \quad \gamma > 0 \tag{3.62}$$

Tout en assurant la stabilité du système augmenté (3.55). Comme déjà mentionné, la condition suivante doit être remplie :

$$\dot{V}(e_a(t)) + e_a^T(t)e_a(t) - \gamma\omega_a^T(t)\omega_a(t) < 0 \tag{3.63}$$

En substituant (3.61) en (3.63), on obtient :

$$\begin{aligned}&\textstyle\sum_{i=1}^{8}\mu_i(z(t))(e_a^T(t)(\tilde{A}_i^TP+P\tilde{A}_i-\tilde{K}_i\tilde{C}-\tilde{C}\tilde{K}_i^T+I)e_a(t)\\&+\omega_a^T(t)(\tilde{R}_i^TP-\tilde{H}^T\tilde{K}_i^T)e_a(t)+e_a^T(t)(P\tilde{R}_i-\tilde{K}_i\tilde{H})\omega_a(t))-\gamma^2\omega_a^T(t)\omega_a(t)<0\end{aligned} \tag{3.64}$$

Ce qui peut être mis sous la forme :

$$\sum_{i=1}^{8}\mu_i(z(t))(\tilde{r}^T(t)\cdot\Xi_i\cdot\tilde{r}(t))<0 \tag{3.65}$$

Où $\Xi_i=\begin{bmatrix}\tilde{A}_i^TP+P\tilde{A}_i-\tilde{K}_i\tilde{C}-\tilde{C}\tilde{K}_i^T+I & P\tilde{R}_i-\tilde{K}_i\tilde{H}\\ \tilde{R}_i^TP-\tilde{H}^T\tilde{K}_i^T & -\gamma^2I\end{bmatrix}$ et $\tilde{r}(t)=\begin{pmatrix}e_a(t)\\ \omega_a(t)\end{pmatrix}$. La condition suffisante pour que (3.63) soit vérifiée est la suivante :

$$\begin{bmatrix}\tilde{A}_i^TP+P\tilde{A}_i-\tilde{K}_i\tilde{C}-\tilde{C}\tilde{K}_i^T+I & P\tilde{R}_i-\tilde{K}_i\tilde{H}\\ \\ \tilde{R}_i^TP-\tilde{H}^T\tilde{K}_i^T & -\gamma^2I\end{bmatrix}<0 \quad , \quad i\in\{1,...,8\} \tag{3.66}$$

3.2.2.4 Résultats de la simulation

L'entrée d'éolienne utilisée dans ce travail dans deux régions est présentée dans le chapitre précédent (le vent). La région 2 est désignée pour l'optimisation de la puissance, et la région 3 correspond à la saturation. Le contrôleur est mis en œuvre avec une fréquence d'échantillonnage de 100 Hz. Les figure 2.7, 3.3 et 3.14 montrent respectivement l'évolution en fonction du temps de la vitesse du vent $\nu_\omega(t)$ (l'entrée), la puissance électrique générée $P_{g,m}(t)$ (la sortie) et le bruit centré proposé $\omega(t)$ dans une séquence temps. Toutes les simulations suivantes sont effectuées pendant une séquence du temps de 4400s, avec les matrices de défauts actionneurs et capteurs et de bruit proposé dans cette proposition soit définie comme :

$$\begin{gathered}F_i=\begin{bmatrix}0.06 & 6 & 1/6 & 89 & 0.01 & 0.001 & 0.01 & 0.001 & 0.01 & 0.001\end{bmatrix}^T,\\ F=\begin{bmatrix}-0.06 & -6 & -89 & -0.01 & -0.01 & -0.01\end{bmatrix}^T\\ \text{et } H=\begin{bmatrix}0.5 & 5 & 0.5 & 0.25 & 0.25 & 0.25\end{bmatrix}^T.\end{gathered}$$

Dans cette stratégie en utilisant l'observateur PMI proposé décrit ci-dessus pour estimer

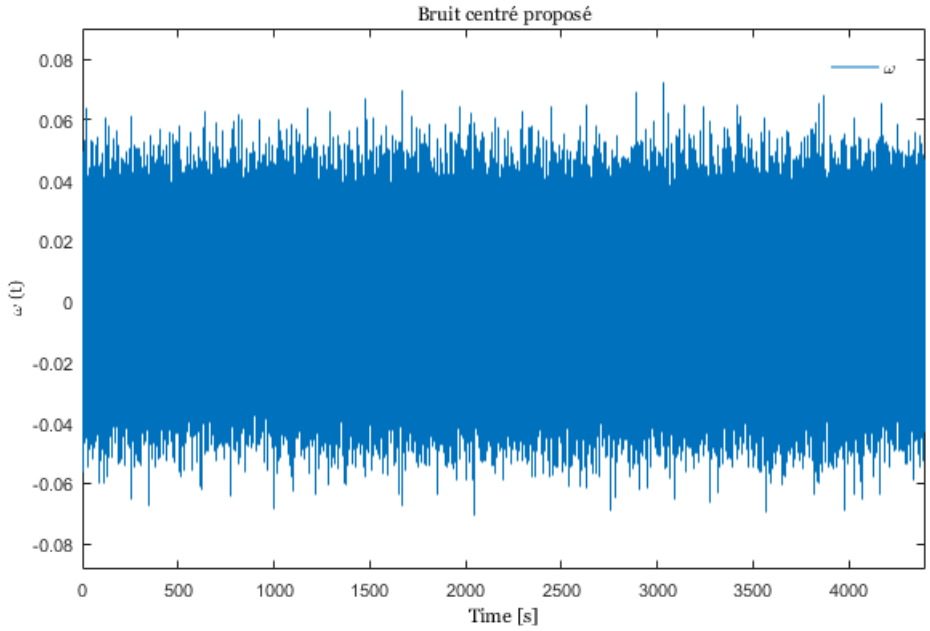


FIGURE 3.14 – Bruit centré proposé $\omega(t)$.

chaque variable de sortie ainsi que les défauts actionneurs et capteurs comme illustré les parties de simulation suivantes :

Angle de position de calage de la pâle 1 "β_1" : La figure 3.15 montre l'estimation de l'angle de calage de la pâle 1 avec l'observateur PMI proposé où $\hat{\beta}_1(t) = \beta_{1,est}$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Angle de position de calage de la pâle 2 "β_2" : La figure 3.16 montre l'estimation de l'angle de calage de la pâle 2 avec l'observateur PMI proposé où $\hat{\beta}_2(t) = \beta_{2,est}$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Angle de position de calage de la pâle 3 "β_3" : La figure 3.17 montre l'estimation de l'angle de calage de la pâle 3 $\hat{\beta}_3$ en utilisant l'observateur PMI proposé où $\hat{\beta}_3(t) = \beta_{3,est}$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Vitesse du générateur "ω_g" : La figure 3.18 montre l'estimation de la vitesse du générateur $\hat{\omega}_g$ en utilisant l'observateur PMI proposé, où $\omega_{g,est} = \hat{\omega}_g$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre

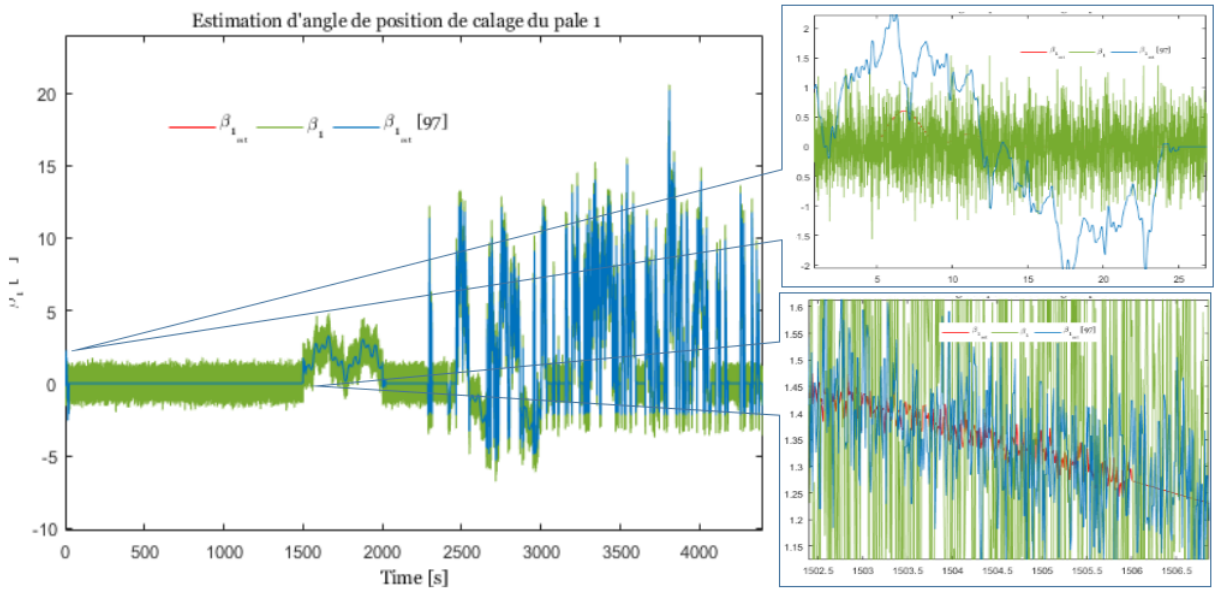


FIGURE 3.15 – Estimation d'angle de position de calage de la pâle 1 $\hat{\beta}_1$.

l'efficacité et la robustesse d'observateur PMI proposé.

Vitesse du rotor "ω_r" : La figure 3.19 montre l'estimation de la vitesse du rotor $\hat{\omega}_r$ en utilisant l'observateur PMI proposé, où $\omega_{r,est} = \hat{\omega}_r$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Couple générateur "τ_g" : La figure 3.20 montre l'estimation du couple générateur $\hat{\tau}_g$ en utilisant l'observateur PMI proposé, où $\tau_{g,est} = \hat{\tau}_g$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Défaut actionneur "f_a" : La figures 3.21(a) montre l'estimation de défaut actionneur proposé $\hat{f}_a$ en utilisant l'observateur PMI proposé, où $f_{a,est} = \hat{f}_a$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

Défaut capteur "f_s" : La figures 3.21(b) montre l'estimation de défaut capteur proposé $\hat{f}_s$ en utilisant l'observateur PMI proposé, où $f_{s,est} = \hat{f}_s$. La comparaison des résultats de simulation de notre proposition par l'approche par mode glissant [**97**] montre l'efficacité et la robustesse d'observateur PMI proposé.

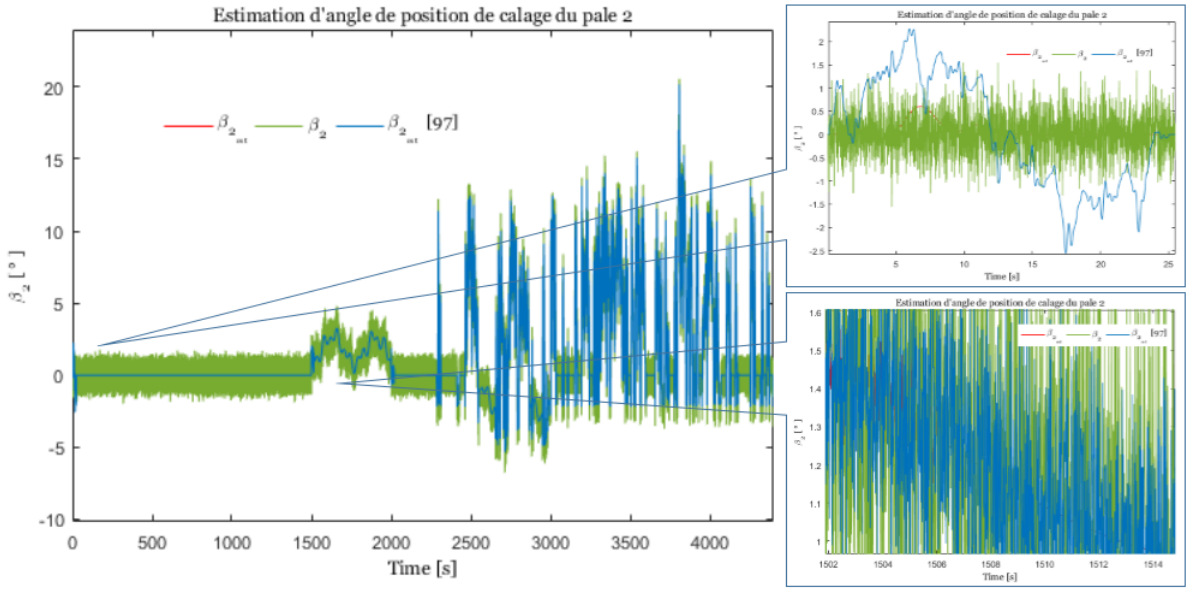


FIGURE 3.16 – Estimation d'angle de position de calage de la pâle 2 $\hat{\beta}_2$.

Enfin, cette approche de diagnostic proposée peut évaluer efficacement tous les états du système d'éolienne (3.24) tout en isolant les défaillances actionneurs et capteurs. Cependant, l'observateur en mode glissant (Sliding Mode (SM)) traité en [**97**] est très sensible aux changements dus au bruit aléatoire et aux défauts inhabituels, puisque les défauts proposé sont typiques (c'est-à-dire triangulaires et rectangulaires dit de forme réglée) sans présence de bruit. Par conséquent, l'observateur PMI proposé est plus efficace et plus robuste que l'observateur en mode glissant [**97**] en ce qui concerne l'estimation et la détection des défauts des systèmes d'éoliennes comme indiquées par la comparaison effectuée dans les résultats de simulations.

3.2.3 Conclusion

Cette section s'intéresse au diagnostic du système éolien à base de modèle, soit par le traitement du système sous leur forme non linéaire ou bien sous leur forme floue multi-modèle TS. Ces méthodes à base d'observateur et celles par estimateurs diffèrent dans la manière de générer des résidus. En effet, considérons le cas où le générateur de résidus se base sur un modèle non linéaire du système éolien ou bien sur un modèle linéarisé autour d'un point de fonctionnement. Lorsque l'état s'écarte sensiblement de ce point de fonctionnement, des dérives importantes peuvent être observées, à cause de ce caractère non-linéaire

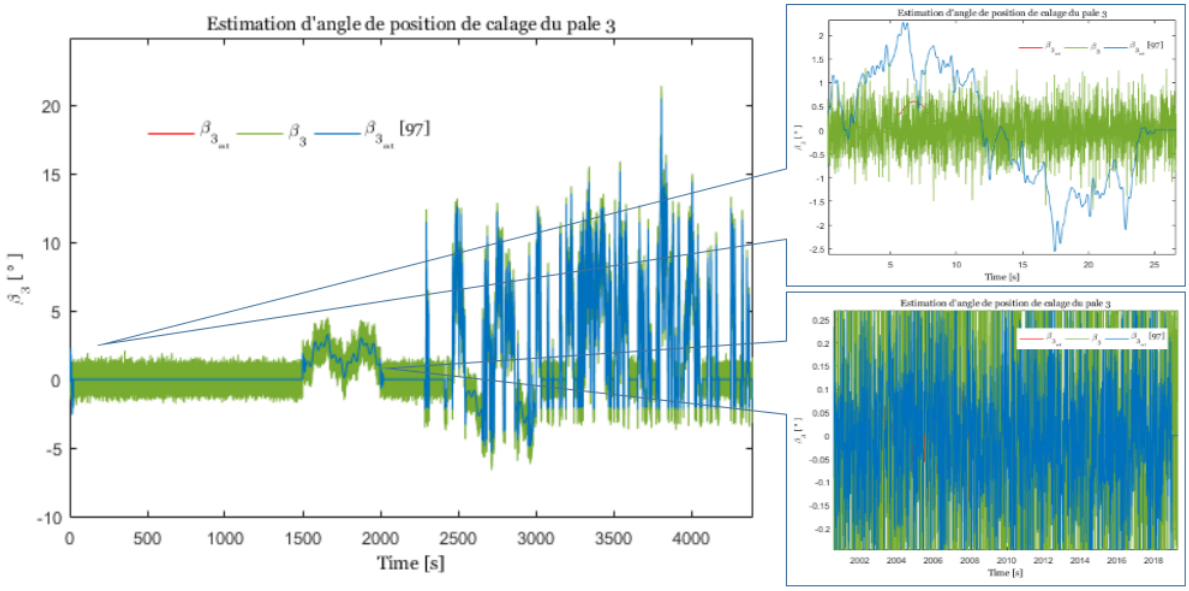


FIGURE 3.17 – Estimation d'angle de position de calage de la pâle 3 $\hat{\beta}_3$.

du comportement. Ces méthodes de diagnostic sont composée de trois fonctions de base : la génération des résidus, la détection, la localisation et éventuellement l'identification. Les limitations de diagnostic à base de modèle ont motivé de chercher à avoir des techniques de diagnostic représentant au mieux le comportement du processus, ont couragées à avoir nouvelles techniques qui n'utilise pas le modèle mathématique.

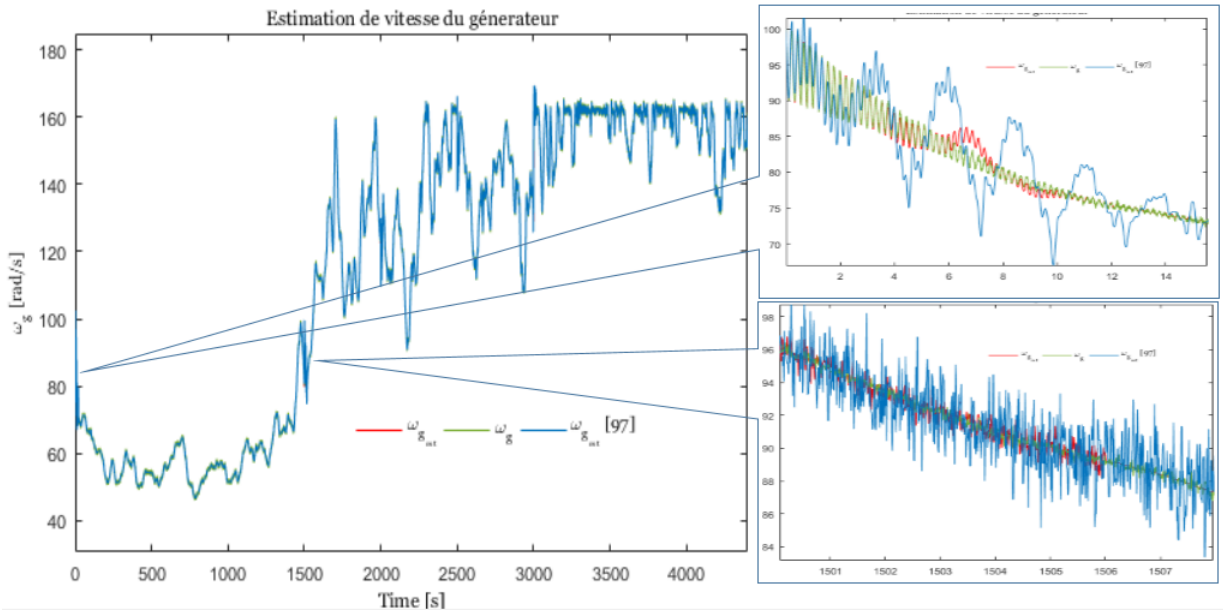


FIGURE 3.18 – Estimation de vitesse du génerateur $\hat{\omega}_g$.

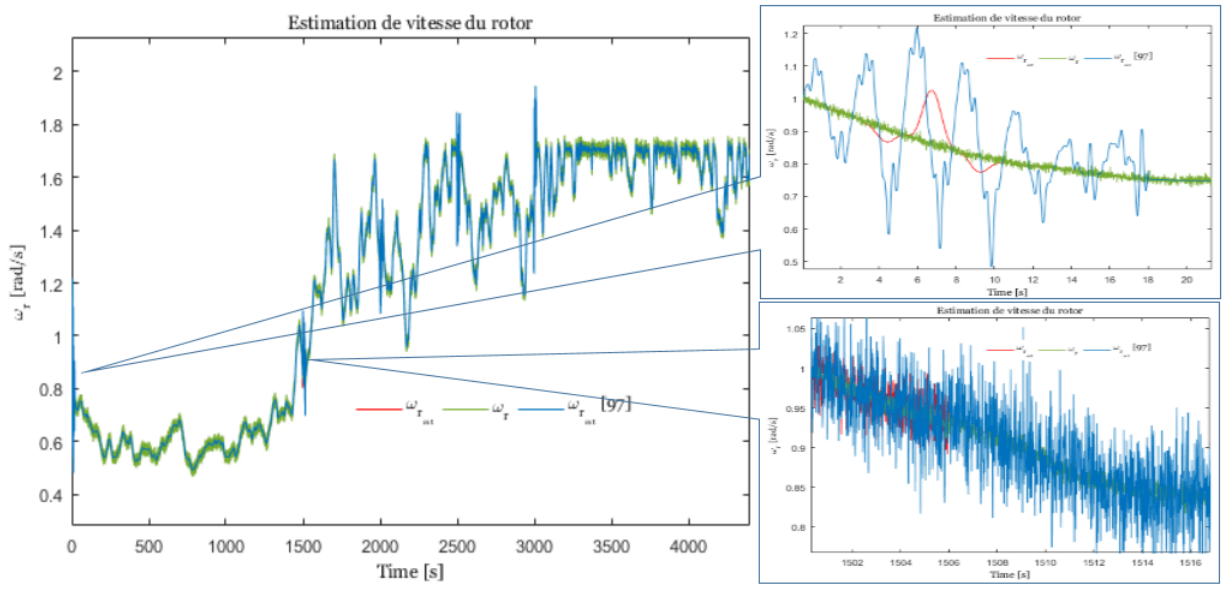


FIGURE 3.19 – Estimation de vitesse du rotor $\hat{\omega}_r$.

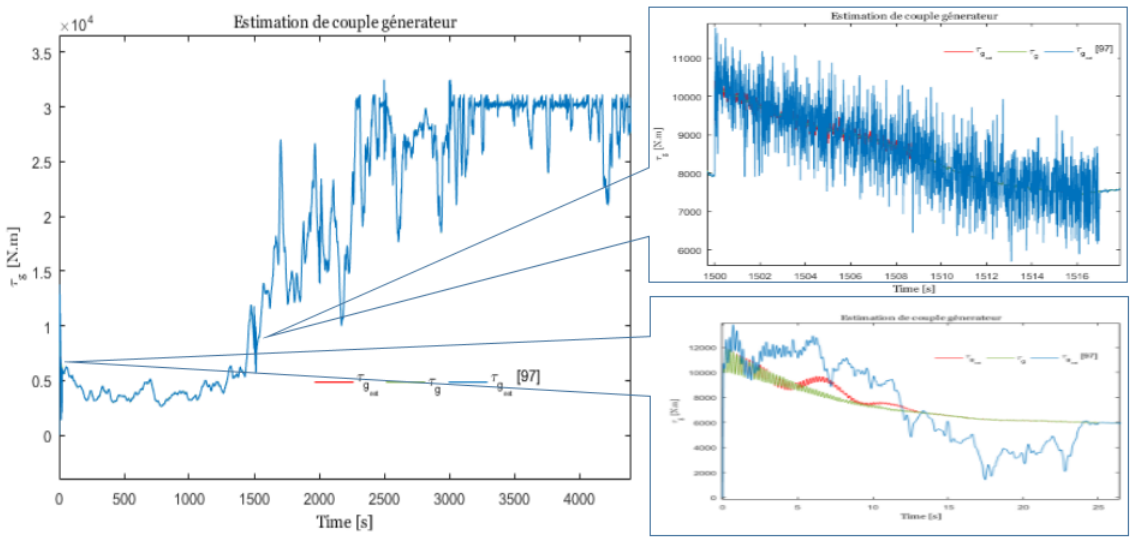


FIGURE 3.20 – Estimation de couple générateur $\hat{\tau}_g$.

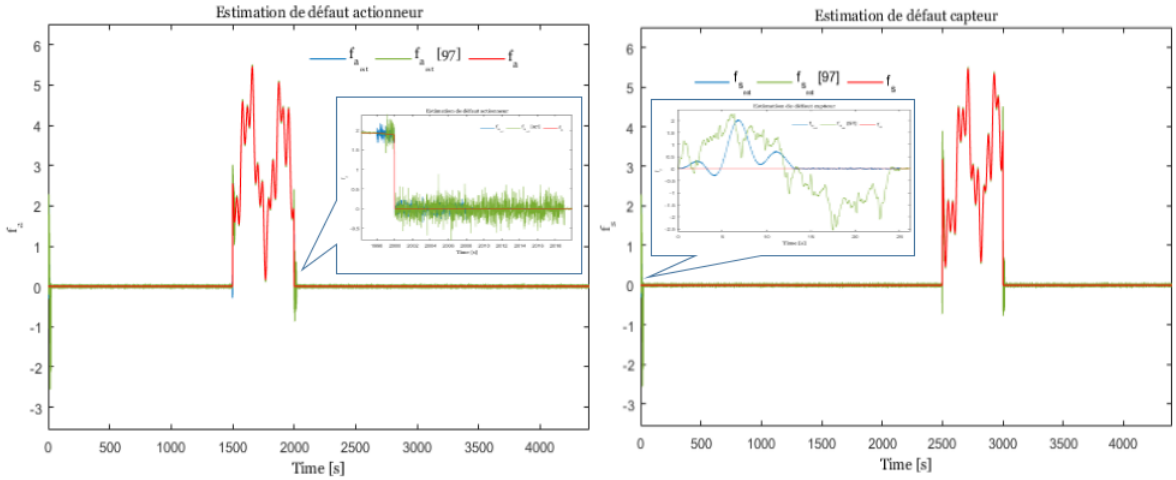


FIGURE 3.21 – Estimation de défaut actionneur f_a et capteur f_s.

3.3 Diagnostic du système éolien à base de données

La disponibilité d'une grande quantité des données ainsi que les inconvénients des méthodes basées sur le modèle (dus à la nécessité d'avoir un modèle précis par exemple), ont encouragé la croissance des méthodes de diagnostic basées sur les données. Ces méthodes peuvent permettre des développements rigoureux des données disponibles (historiques ou en temps réel) même dans le cas de systèmes complexes, d'où leur succès dans les applications industrielles. Elles font appel à des procédures d'apprentissage et de reconnaissance de forme, à la logique floue ou à l'intelligence artificielle afin de générer les symptômes de défaut qui seront analysés pour fournir la décision de diagnostic de défaut [**99**].

Les méthodes basées sur les données sont appropriées pratiquement pour n'importe quel type de problème pour lequel d'importantes quantités de données mesurées représentatives du fonctionnement du système sont disponibles. Elles sont d'autant plus intéressantes lorsque le modèle mathématique du système n'est pas disponible, ce qui rend inutilisables les méthodes de diagnostic basées sur le modèle. L'application de ces méthodes est réalisée pour le système éolien en différentes étapes d'acquisition et prétraitement des données, de modélisation / apprentissage et de validation comme il est illustré sur la figure 3.22.

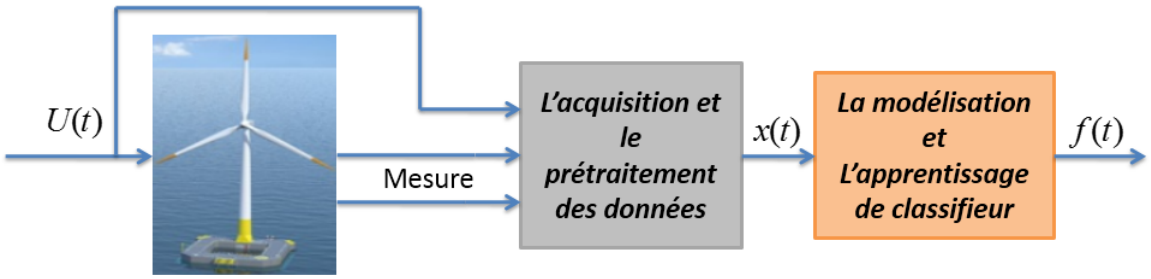


FIGURE 3.22 – Structure principale de diagnostic à base de données pour le système éolien.

L'idée derrière nos stratégies de diagnostic de défaut dédié aux éoliennes est de voir le problème du diagnostic comme un problème de classification. Premièrement, une méthode de diagnostic du système éolien par un classifieur basé sur l'adaptation de la machine à vecteurs de support (Support Vector Machine "SVM") avec la logique floue est proposée. SVM classification est utilisée pour évaluer les résidus générés ainsi que d'autres caractéristiques afin de conclure sur l'état de fonctionnement du système. Par la suite l'évaluation de l'erreur de classification sert l'ajustement des paramètres du classifieur en utilisant la logique floue. Ce principe permet de réaliser un classifieur adaptatif, capable de traiter tous les

différents types de défauts qui atteignent le système éolien. Il est d'abord essentiel de bien comprendre le système éolien et comment il fonctionne avant d'envisager de réaliser la stratégie de diagnostic de défaut. Deuxièment, un classifieur hybride est proposé comme une combinaison de trois approches : algorithme statistique de Bayes, réseaux de neurones à rétropropagation et arbres de décision. Ce classifieur hybride proposé a été construit à l'aide de la bibliothèque "Environnement de Waikato pour l'analyse des connaissances" (Waikato Environment for Knowledge Analysis 'WEKA') pour évaluer et observer le taux de classification de ce classifieur.

3.3.1 Préparation des données

L'idée clé de la préparation des données dans cette section de diagnostic des défauts à base de données pour l'éolienne est la définition du vecteur des données x à utiliser pour la classification. Ce vecteur doit inclure l'information la plus pertinente du comportement du système relatif à un défaut donné.

Il peut contenir les sorties mesurées, des mesures décalées, les entrées, les consignes, une combinaison de celles-ci ou la variation des sorties avec le temps. Afin de construire un vecteur utile, il faut observer attentivement les mesures de sorties du processus pour chaque anomalie et proposer une combinaison qui assure un fort impact de défaut considéré dans le vecteur x.

Plusieurs vecteurs sont proposés pour différents types de défauts. La redondance matérielle (capteurs dupliqués) est utilisée comme une caractéristique dans la plupart de ces vecteurs. La plupart des données sont filtrées par un filtre de premier ordre avec une constante de temps τ afin de réduire la sensibilité aux perturbations du procédé ou aux bruits de mesures.

Les défauts pris dans ce travail sont les défauts proposés pour le modèle d'éolienne présenté dans le tableau 3.1.

3.3.1.1 Diagnostic des défauts de capteurs de système de calage de la pâle

Pour les 6 capteurs mesurant les positions de système de calage de la pâle ($\Delta\beta_{k,mi}$; $k = 1, 2, 3$; $i = 1, 2$) :

Défauts de type valeur fixe : Pour ces défauts, le vecteur suivant est utilisé pour la détection et l'isolation :

$$x = \begin{bmatrix} |\check{\beta}_{k,m1}(t_j) - \check{\beta}_{k,m2}(t_j)| \\ \\ |\beta_{k,m1}(t_j) - \beta_{k,m1}(t_{j-1})| \\ \\ |\beta_{k,m2}(t_j) - \beta_{k,m2}(t_{j-1})| \end{bmatrix} \tag{3.67}$$

Où t_j et t_{j-1} sont les instants du temps j et $j-1$ respectivement et $\check{\beta}$ est la valeur filtrée de β par un filtre passe-bas avec une constante de temps $\tau = 0.06s$. Notez que les valeurs absolues sont utilisées dans x. Lorsque $|\beta_{k,mi}(t_j) - \beta_{k,mi}(t_{j-1})|$ est significative ; avec $k = 1, 2, 3$; $i = 1, 2$, ce terme est remplacé par une large valeur constante (5000) afin d'améliorer la distinction entre le défaut de type valeur fixe et le cas normal (sans défaut).

Défauts de type gain : Ce défaut est détecté et isolé en deux étapes.

Tout d'abord, le défaut est détecté en utilisant le vecteur suivant :

$$x = \begin{bmatrix} |\check{\beta}_{k,m1}(t_j) - \check{\beta}_{k,m2}(t_j)| \\ \\ |\check{\beta}_{k,m1}(t_j) - \check{\beta}_{k,m1}(t_{j-1})| \\ \\ |\check{\beta}_{k,m2}(t_j) - \check{\beta}_{k,m2}(t_{j-1})| \end{bmatrix} \tag{3.68}$$

Les deux dernières lignes dans le vecteur (3.68) ci-dessus sont importantes afin d'exclure les défauts de type valeur fixe. Par la suite, si le défaut de type gain est détecté, le vecteur suivant est utilisé pour l'isolation entre les capteurs 1 et 2 :

$$x = \begin{bmatrix} |\check{\beta}_{k,r}(t_j) - \check{\beta}_{k,m1}(t_j)| \\ \\ |\check{\beta}_{k,r}(t_j) - \check{\beta}_{k,m2}(t_j)| \end{bmatrix} \tag{3.69}$$

Où $\beta_{k,r}$ est la valeur désirée de l'angle pitch β_k et $\check{\beta}$ est la valeur filtrée par un filtre passe-bas de constante de temps $\tau = 0.08s$.

Défauts associé à l'actionneur : Pour la détection de défauts associé à l'actionneur

nous avons utilisé le vecteur suivant :

$$x = \begin{bmatrix} |\omega_{g,m1}(t_j) - \omega_{g,m2}(t_j)| \\ \\ |\beta_{k,m1}(t_j) - \beta_{k,m2}(t_j)| \\ \\ |\beta_{k,m1}(t_j) - \beta_{k,m1}(t_{j-1})| \\ \\ |\beta_{k,m2}(t_j) - \beta_{k,m2}(t_{j-1})| \end{bmatrix} \tag{3.70}$$

Une fois les vecteurs d'apprentissage définis pour chaque défaut, les scénarios de défauts sont simulés et à chaque échantillon est attribué $z = \pm 1$ (avec ou sans faute) pour chaque type de défauts.

3.3.1.2 Diagnostic des défauts capteurs des vitesses de génératrice et du rotor

Pour des défauts capteurs dans les vitesses de la génératrice et du rotor ($\omega_{g,mi}$, $\omega_{r,mi}$; $i = 1, 2$) :

Défauts de type valeur fixe : Pour la détection des défauts de type valeur fixe, le vecteur suivant est utilisé pour la détection et l'isolation :

$$x = \begin{bmatrix} |\breve{\omega}_{p,m1}(t_j) - \breve{\omega}_{p,m2}(t_j)| \\ \\ |\omega_{p,m1}(t_j) - \omega_{p,m1}(t_{j-1})| \\ \\ |\omega_{p,m2}(t_j) - \omega_{p,m2}(t_{j-1})| \end{bmatrix} \quad ; \quad p = g, r \tag{3.71}$$

$\breve{\omega}_g$ et $\breve{\omega}_r$ sont obtenus en utilisant des filtres avec $\tau = 0.02s$ et $\tau = 0.6s$ respectivement. Lorsque le terme $|\omega_{p,mi}(t_j) - \omega_{p,mi}(t_{j-1})|$ est significative, avec $i = 1, 2$, il est remplacé par une grande valeur constante dans le vecteur de caractéristique x afin d'améliorer la distinction entre le défaut de valeur fixe et le cas normal (sans défaut) et faciliter la tâche du classifieur.

Défauts de type gain : Pour la détection des défauts de type gain (sans les défauts

de type valeur fixe), le vecteur suivant est utilisé en première étape :

$$x = \begin{bmatrix} |\breve{\omega}_{p,m1}(t_j) - \breve{\omega}_{p,m2}(t_j)| \\ |\breve{\omega}_{p,m1}(t_j) - \breve{\omega}_{p,m1}(t_{j-1})| \\ |\breve{\omega}_{p,m2}(t_j) - \breve{\omega}_{p,m2}(t_{j-1})| \end{bmatrix} \quad ; \quad p = g, r \tag{3.72}$$

Les mesures sont filtrées par des filtres passe-bas avec leur constante de temps égale à $\tau = 0.6s$ et $\tau = 0.02s$ pour $\breve{\omega}_r$ et $\breve{\omega}_g$ respectivement.

Dans une seconde étape, l'isolation entre les capteurs 1 et 2 dans le cas de défaut de type gain est faite en utilisant le vecteur suivant :

$$x = \begin{bmatrix} \frac{\breve{\tau}_{g,m}(t_j) \times \breve{\omega}_{p,m1}(t_j) \times c_p}{\breve{P}_{g,m}(t_j)} \\ \\ \frac{\breve{\tau}_{g,m}(t_j) \times \breve{\omega}_{p,m2}(t_j) \times c_p}{\breve{P}_{g,m}(t_j)} \end{bmatrix} \quad ; \quad p = g, r \quad avec \quad c = \begin{cases} c_g = 10 \\ \\ c_r = 1000 \end{cases} \tag{3.73}$$

Où $P_{g,m}$ et $\tau_{g,m}$ sont la mesure de la puissance générée de la génératrice et la mesure du couple générateur respectivement à l'instant t_j. Les mesures sont filtrées par un passe bas avec leur constante de temps égal à $\tau = 0.6s$ et $\tau = 0.06s$ pour la vitesse du rotor et du générateur $\breve{\omega}_r$ et $\breve{\omega}_g$ respectivement.

3.3.1.3 Diagnostic des défauts du convertisseur et du système

Pour les défauts du convertisseur et du système, le vecteur suivant est utilisé :

$$x = \begin{bmatrix} |\omega_{g,m1}(t_j) - \omega_{g,m2}(t_j)| \\ \\ |\tau_{g,r}(t_j) - \tau_{g,m}(t_j)| \\ \\ \lambda_2 \times |\omega_{g,r}(t_j) - \frac{(\omega_{g,m1}(t_j) - \omega_{g,m2}(t_j))}{2}| \end{bmatrix} \tag{3.74}$$

Où $\omega_{g,r} = \frac{P_r}{\tau_{g,r}}$ est la vitesse de la génératrice désirée calculée à partir du couple générateur désiré $\tau_{g,r}$ obtenu par le contrôleur avec P_r la puissance désirée. Le facteur $\lambda_2 = 10^{-10} \times \nu_\omega^6$ dans la 3ème composante de x est utilisé pour tenir compte de la vitesse du vent et pour la normalisation (avoir le même ordre de grandeur). Notons également que $\tau_{g,r}$ est filtré en

utilisant un filtre du premier ordre avec une constante de temps $\tau = 0,02s$. L'objectif de ce filtre est de prendre en compte la dynamique du système de contrôle (temps nécessaire pour $\tau_{g,m}$ pour atteindre $\tau_{g,r}$) et non de rejeter le bruit de mesure ou les perturbations.

Remarque 3.3 : Le filtre utilisé est un filtre pass bas pour réduire la sensibilité aux perturbations du processus ou bruit de mesure.

3.3.2 Classifieur basé sur l'adaptation de machine à vecteurs de support (SVM) par la logique floue pour le diagnostic du système éolien

Le modèle de diagnostic proposé est basé sur l'adaptation de la technique Machine à Vecteurs de Support (SVM) par la logique floue. Il a été développé en quatre étapes, tout d'abord la première étape est consacrée pour faire l'apprentissage de notre classifieur, cet apprentissage a été réalisé par des données prises à partir des capteurs et préparé suivant des vecteurs de mesures présentées ci-dessus, par la suite dans la deuxième étape nous avons pris ce classifieur obtenu pour valider son efficacité de classification par les vecteurs de mesures au cours du fonctionnement du système éolien, enfin dans la dernière étape nous avons adapté les paramètres du classifieur à l'aide de la logique floue pour avoir plus d'éfficacité et de robustesse.

Dans ce cas les données ne sont pas linéairement séparables au niveau de classifieur SVM, alors l'idée est de modéliser les erreurs potentielles par des variables d'écart positives ξ_i associées à chacune des observations $(x_i; y_i)\,;\, i \in [1; n]$.

Alors le problème de classifieur SVM devient à chercher les paramètres w et b, qui définissent l'hyperplan de séparation, en minimisant la fonction objectif suivante sur tous les n exemples d'apprentissage :

$$\delta(w, e) = \frac{1}{2}\|w\|^2 + C\sum_{i=1}\xi_i \tag{3.75}$$

Sous les contraintes : $\forall i = i, \ldots, N : y_i(K(x_i, x) + b) \geq 1 - \xi_i\,;\, e_i \geq 0$.

Dans cette fonction objective, chaque variable d'erreur ξ_i montre la quantité d'erreur que le classifieur fait sur un exemple donné x_i. La minimisation du somme des variables d'erreur correspond à minimiser la fonction de perte des données d'entraînement, tout en

minimisant le terme correspond à maximiser la marge entre les deux classes.

3.3.2.1 Adaptation de Classifieur SVM par la logique floue

Parmi les inconvénients majeurs posés par classifieur SVM [**99**], est que leurs paramètres (w et b) ne changent plus après l'étape d'apprentissage, ce qui ne permet pas à détecter quelques types des défauts (les défauts système 6 et 7) qui sont difficiles à détecter et à isoler. Pour résoudre ce problème, nous avons proposé dans cette étude un algorithme basé sur la logique floue pour ajuster et adapter les paramètres de l'hyperplan de classifieur SVM w et b suivant la stratégie présentée dans la figure 3.23. Les paramètres initiaux du noyau sont obtenus au cours de l'étape d'apprentissage, puis en utilisant respectivement Δw et Δb pour l'adaptation du w et b conformément à l'équation suivante :

$$\begin{cases} w' = w + \Delta w \\ \\ b' = b + \Delta b \end{cases} \tag{3.76}$$

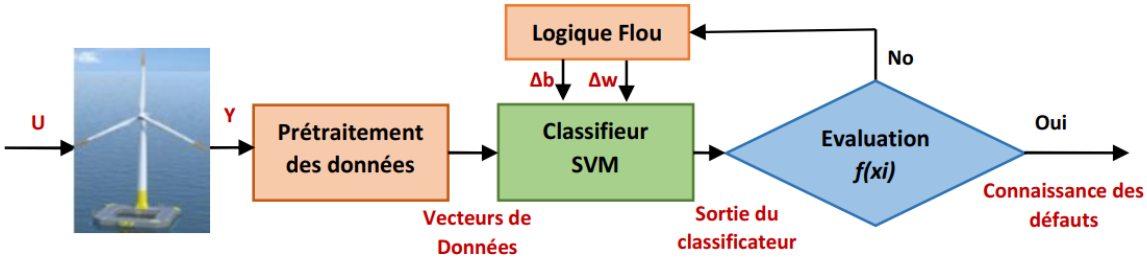


FIGURE 3.23 – Schéma global de stratégie du diagnostic de l'éolienne par le classifieur adaptatif proposé.

La structure génerale proposée pour l'adaptation du classifieur SVM se déroule suivant l'algorithme 3.1 :

(1)- Début {

(2)- Lire les mesures d'après les capteurs ;

(3)- Préparer les vecteurs x_i des données ;

(4)- Classifier les données d'après le classifieur ;

(5)- Lire la sortie de fonction de la décision de classifieur $f(x_i)$;

(6)- **Si** $f(x_i) \leq m$

(7)- L'index de défaut = 0 ; Absence de défauts.

(8)- $s = 0$; Désactiver le mode d'adaptation.

(9)- **Fin Si.**

(10)- **Sinon Si** $f(x_i) \geq M$

(11)- L'index de défaut = 1 ; Présence de défauts.

(12)- $s = 0$; Désactiver le mode d'adaptation.

(13)- **Fin Si.**

(14)- **Sinon** ($m < f(x_i) < M$)

(15)- $s = 1$; Activer le mode d'adaptation : Ajuster les paramètres de fonction de la décision de classifieur.

(16)- **Fin Sinon.**

(17)- Fin. }

ALGORITHME 3.1 : Fonctionnement de la méthode proposée.

Où m et M sont des paramètres de réglage, ils sont proposés pour chaque défaut différent comme illustre le tableau 3.4.

Les règles floues proposées sont exprimées sous la forme générale :
"Si A_i et B_i, Alors C_i".

Alors, dans cette étude les variables linguistiques sont la sortie de fonction décision $f(x_i)$ et leur dynamique $df(x_i)$. Et les règles floues pour générer Δw et Δb respectivement sont exprimées dans les tableaux 3.5 et 3.6, avec les fonctions d'appartenance pour les variables d'entrée et de sortie se présentent sous la forme des fonctions trigonométriques.

Où les termes linguistiques d'entrée $f(x_i)$ et leur dynamique $df(x_i)$ sont exprimés comme : plus négatif (Negative Big 'NB'), peu négatif (Negative Small 'NS'), zéro (Zero 'ZO'), peu positif (Positive Small 'PS') et plus positif (Positive Big 'PB'). Et les termes linguistiques de sortie Δw et Δb sont : plus (Big 'B'), moyen (Medium 'M'), petit (Small 'S') et zéro (Zero 'ZO').

Défaut	Valeurs des paramètres
Défaut 1	m = 0 M = 0.05
Défaut 2	m = 0 M = 0.05
Défaut 3	m = 0 M = 0.05
Défaut 4	m = 0 M = 0.05
Défaut 5	m = 0 M = 0.05
Défaut 6	m = 0.5 M = 1
Défaut 7	m = 0.5 M = 1
Défaut 8	m = 0.6 M = 0.8

TABLE 3.4 – Valeurs de m et M pour chaque défaut.

Δw		$f(x_i)$				
		NB	NS	ZO	PS	PB
$df(x_i)$	NB	B	M	S	M	B
	NS	B	S	ZO	S	B
	ZO	B	S	ZO	S	B
	PS	B	S	ZO	S	B
	PB	B	M	S	M	B

TABLE 3.5 – Règles floues pour Δw.

Δb		$f(x_i)$				
		NB	NS	ZO	PS	PB
$df(x_i)$	NB	B	B	S	B	ZO
	NS	B	M	S	M	ZO
	ZO	M	S	M	S	M
	PS	ZO	M	S	M	B
	PB	ZO	B	S	B	B

TABLE 3.6 – Règles floues pour Δb.

3.3.2.2 Les résultats de simulations

Environ sept scénarios ont été envisagés pour chaque défaut avec des amplitudes de défauts différents. L'algorithme d'apprentissage SVM utilise les vecteurs de caractéristiques (x) et les valeurs z correspondantes pour identifier α_i et les vecteurs de support (x_{sup}) nécessaires pour la prise de décision. L'identification dépend du type du noyau et des paramètres de réglage : α et C. Une bonne adaptation des paramètres d'apprentissage de classifieur SVM avec la logique floue évite le surapprentissage. L'approche essaie-test a été adoptée dans cette application, elle consiste à réaliser plusieurs essais avec différentes valeurs des paramètres C et α et de les tester sur un ensemble de tests. Notons que le même «modèle» (x_{sup} et α) est utilisé pour tous les défauts de type valeur fixe, un autre «modèle» pour tous les défauts de type gain et ainsi de suite, donc dix «modèles» ont été développés. Étant donné que le système d'éoliennes traité dans cette étude est composé de trois actionneurs de calage de la pâle, du générateur et du système d'entrainement, le diagnostic proposé a été présenté et décrit pour chaque défaut tout seul de la manière suivante :

Défaut 1 : Le défaut 1 est un défaut capteur de type valeur fixe qui affecte le premier capteur qui mesure l'angle de position de calage de la pâle 1 $\beta_{1,m1}$, ce défaut s'exprime comme la fixation de $\beta_{1,m1}$ à une valeur de 5° pendant l'intervalle du temps [2000, 2100]. La figure 3.24 illustre le résultat de détection et d'isolation du défaut 1 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec le paramètre σ de la fonction noyau gaussienne est régulé à 10.

Défaut 2 : Le défaut 2 est un défaut de type gain qui affecte le deuxième capteur qui mesure l'angle de position de calage de la pâle 2 $\beta_{2,m2}$, ce défaut s'exprime comme la multiplication de $\beta_{2,m2}$ par un scalaire d'amplitude 1.2 pendant l'intervalle du temps [2300, 2400]. La figure 3.25 illustre le résultat de détection et d'isolation du défaut 2 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec le paramètre σ de la fonction noyau gaussienne est régulé à 10.

Défaut 3 : Le défaut 3 est un défaut capteur de type valeur fixe qui affecte le premier capteur qui mesure l'angle de position de calage de la pâle 3 $\beta_{3,m1}$, ce défaut s'exprime comme la fixation de $\beta_{3,m1}$ à une valeur de 10° pendant l'intervalle du temps [2600, 2700]. La figure 3.26 illustre le résultat de détection et d'isolation du défaut 3 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec le paramètre σ de la fonction noyau gaussienne est régulé à 10.

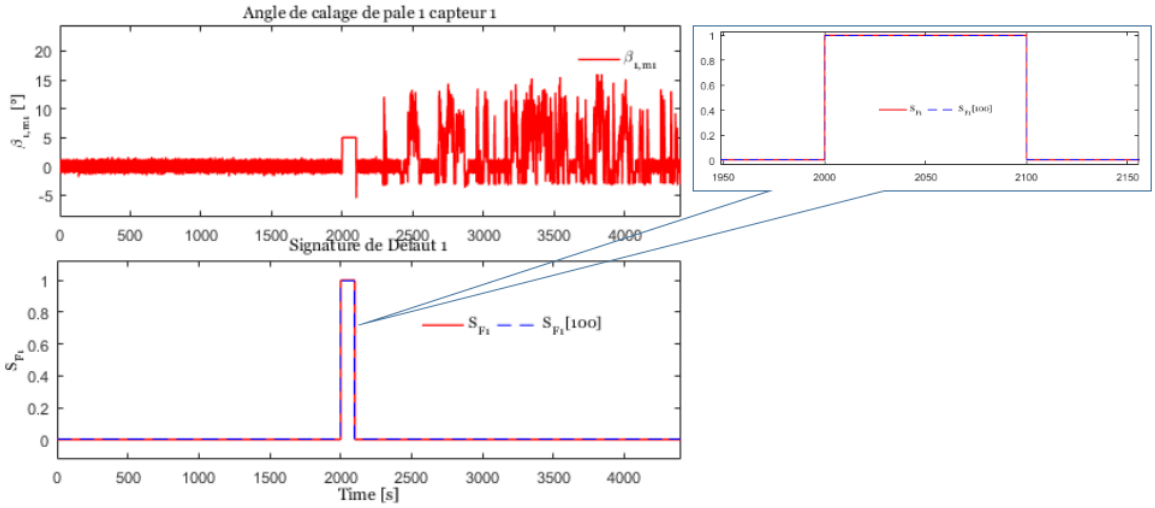


FIGURE 3.24 – Détection et isolation de défauts 1 par le classifieur adaptatif proposé.

Défaut 4 : Le défaut 4 est un défaut capteur de type valeur fixe qui affecte le premier capteur qui mesure la vitesse de rotation du rotor $\omega_{r,m1}$, ce défaut s'exprime comme la fixation de à une valeur de $\omega_{r,m1}$ à une valeur de $1.4 rad/s$ pendant l'intervalle du temps [1500, 1600]. La figure 3.27 illustre le résultat de détection et d'isolation du défaut 4 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec la variance gaussienne est régulé à $\sigma = 15$ pour améliorer la croissance de la capacité de détection.

Défaut 5 : Le défaut 5 est un défaut de type gain qui affecte les deuxièmes capteurs qui mesurent la vitesse de rotation du rotor $\omega_{r,m2}$ et la vitesse de rotation du générateur $\omega_{g,m2}$, ce défaut s'exprime comme la multiplication des deux capteur $\omega_{r,m2}$ et $\omega_{g,m2}$ par un scalaire d'amplitude 1.1 et 0.9 respectivement pendant l'intervalle du temps [1000, 1100]. Les figures 3.28 et 3.29 illustrent les résultats de détection et d'isolation du défaut 5 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec la variance gaussienne est régulé à $\sigma = 15$ pour améliorer la croissance de la capacité de détection.

Défaut 6 : Le défaut 6 est un défaut système du type changement de dynamique du système de calage de la pâle 2 causé par une forte teneur en air dans l'huile, ce défaut représenté par le changement de la pulsation propre non amortie w_{n2} de 11.11 à 5.73 et de coefficient d'amortissement ζ_2 de 0.6 à 0.45 pendant l'intervalle du temps [2900, 3000]. La figure 3.30 illustre le résultat de détection et d'isolation du défaut 6 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**],

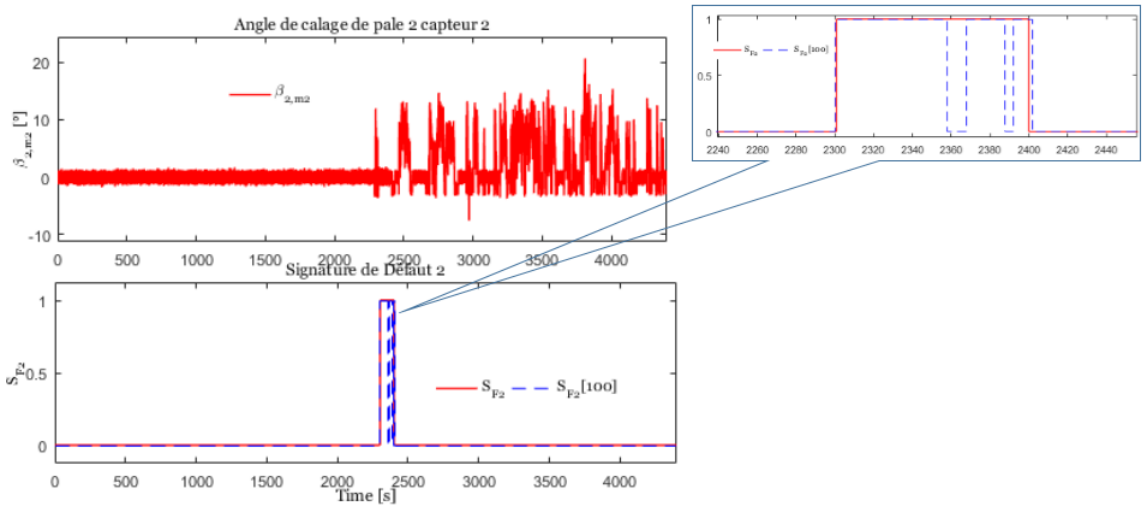


FIGURE 3.25 – Détection et isolation de défauts 2 par le classifieur adaptatif proposé.

avec le paramètre σ de la fonction noyau gaussienne est régulé à 10.

Défaut 7 : Le défaut 7 est un défaut système du type changement de dynamique du système de calage de la pâle 3 provoqué par une chute de pression de la canalisation principale, ce défaut représenté par le changement de la pulsation propre non amortie w_{n3} de 11.11 à 3.42 et de coefficient d'amortissement ζ_3 de 0.6 à 0.9 pendant l'intervalle du temps [3400, 3500]. La figure 3.31 illustre le résultat de détection et d'isolation du défaut 7 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec le paramètre σ de la fonction noyau gaussienne est régulé à 10.

Défaut 8 : Le défaut 8 est un défaut du convertisseur de type additif provoqué par une chute de pression de la canalisation principale, ce défaut représenté par le décalage du coule génératrice τ_g de τ_g à $\tau_g + 2000Nm$ pendant l'intervalle du temps [3800, 3900]. La figure 3.32 illustre le résultat de détection et d'isolation du défaut 8 par le classifieur adaptatif proposé en le comparant avec le résultat de classifieur SVM [**100**], avec le paramètre $\sigma = 10$ pour ce défaut du convertisseur.

Le tableau 3.7 montre le temps qui prend le classifieur pour détecter chaque défaut, dont lequel aussi on montre le déficit subi par le classifieur SVM [**100**] pour détecter et isoler les deux défauts système (défauts 6 et 7), au contraire notre classifieur adaptatif proposé a été capable de détecter tous les défauts proposés avec réussite.

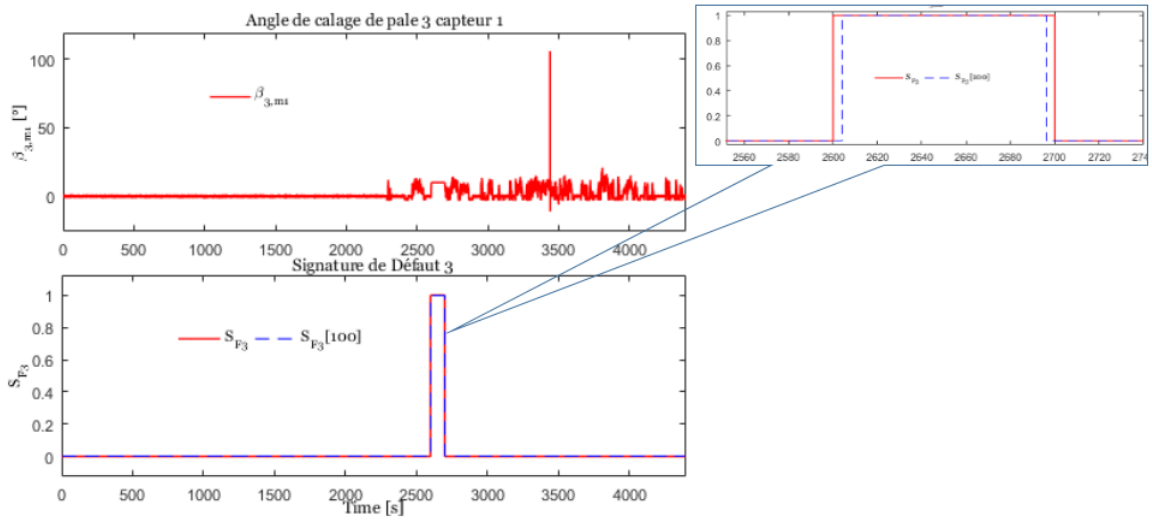


FIGURE 3.26 – Détection et isolation de défauts 3 par le classifieur adaptatif proposé.

3.3.3 Classifieur hybride pour la détection et l'isolation des défauts dans le système éolien

Dans cette proposition, le problème du diagnostic dans le système éolien sera traité. L'idée est de construire un classifieur à l'aide de la bibliothèque "Environnement de Waikato pour l'analyse des connaissances" (Waikato Environment for Knowledge Analysis 'WEKA') pour classer les données en deux classes, afin que nous peuvons décider si l'état du système est défectueux ou non [**101**]. Par ailleurs, nous avons injecté des bruits dans tous les capteurs de mesures du système éolien. Outre, plus des défauts présentés dans le tableau 3.1 ont provoqué un bruit dans les capteurs, cela ramène le problème du diagnostic très difficile à traiter. Pour résoudre ce problème dans ces conditions, nous avons utilisé trois approches complémentaires pour construire un classifieur hybride. Premièrement l'algorithme bayésien statique, permettant d'exploiter l'indépendance conditionnelle des entités. Mais il envoie l'inférence dans une fausse direction si l'information préalable est fausse. Donc, pour résoudre ce problème, nous avons ajouté la deuxième approche, celle des réseaux de neurones à apprentissage de type rétropropagation, mais le temps d'apprentissage reste très élevé. Par conséquent, et pour accélérer le temps d'apprentissage sans perdre la qualité de classification nous avons ajouté les arbres de décision, qui nous donnent une rapidité pour l'apprentissage et pour la classification aussi pour le classifieur hybride proposé.

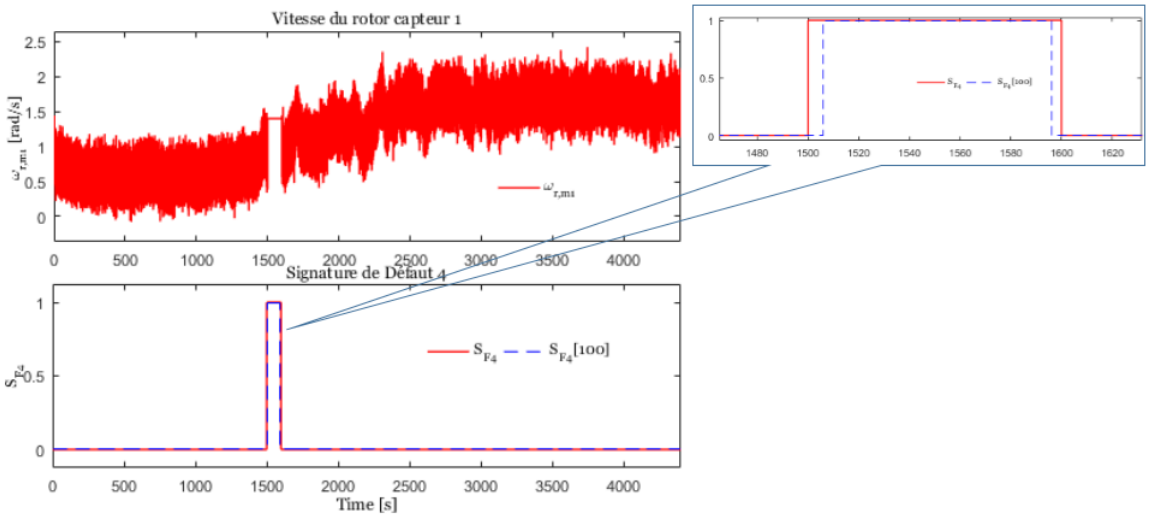


FIGURE 3.27 – Détection et isolation de défauts 4 par le classifieur adaptatif proposé.

3.3.4 Résultats de simulations

En effet, nous prenons un échantillon de mesures de capteurs pour différents vecteurs x de données proposés pour les différents types de défauts ressemblent les vecteurs des données proposés précédement. Au terme d'analyse, une comparaison des performances de classifieur hybride proposé par rapport au classifieur naïve Bayesian [**102**] et au classifieur basé sur le réseau de neurones à apprentissage de type rétropropagation [**103**] et au classifieur basé sur l'induction d'arbres de décision [**104**], a été présenté dans le tableau 3.8 pour indiquer la précision de classification et le temps d'apprentissage pour chaque classifieur. Le classifieur proposé basé sur une combinaison de l'approche Naïve Bayesian et du réseau de neurones à apprentissage par rétropropagation et de l'arbre de décision. Puisque ce classifieur hybride proposé est un ensemble de ces trois approches, cela permet à ce classifieur d'exploiter les avantages de chaque approche pour construire un classifieur à plus de performances. Tout d'abord, le classifieur naïf bayesian peut être étendu pour exploiter l'indépendance conditionnelle des fonctionnalités. Deuxièmement, le classifieur basé sur le réseau de neurones inclut leur tolérance élevée aux données bruitées ainsi que leur capacité à classer des modèles sur lesquels ils n'ont pas été formés. Troisièmement, l'efficacité de l'algorithme de l'arbre de décision pour des ensembles de données relativement petits. La comparaison mentionnée dans le tabeau 3.7 indique l'efficacité de notre proposition par rapport au autres classifieurs. Pour valider nos résultats, nous avons utilisé la bibliothèque d'apprentissage automatique "WEKA".

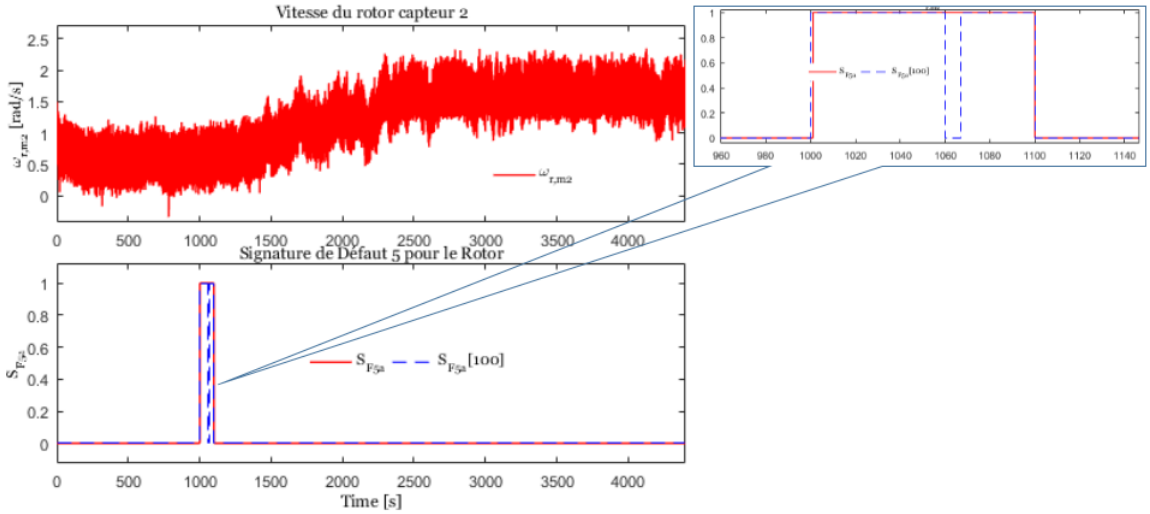


FIGURE 3.28 – Détection et isolation de défauts 5 par le classifieur adaptatif proposé pour le rotor.

Les résultats obtenus sont repris dans le tableau 3.8 ci-après. Où T_C est le temps nécessaire à la construction du modèle en seconde (s) et P_R est la précision de la reconnaissance (la classification correcte des données) en pourcentage (%).

Défaut	Diagnostic par le classifieur SVM [100]	Diagnostic par le classifieur adaptatif proposé	Temps de Détéction
Défaut 1	Oui	Oui	2000.00
Défaut 2	Oui	Oui	2301.33
Défaut 3	Oui	Oui	2600.51
Défaut 4	Oui	Oui	1500.35
Défaut 5	Oui	Oui	1000.01
Défaut 6	Non	Oui	2951.00
Défaut 7	Non	Oui	3409.68
Défaut 8	Oui	Oui	3800.01

TABLE 3.7 – Résultats de détection et d'isolation des défauts par le classifieur adaptatif proposé.

Classifieur / **Défaut**	**Classifieur Naive Bayesian [102]**	**Classifieur Rétro-propagation [103]**	**Classifieur d'arbre de décision [104]**	**Classifieur Hybride Proposé**
Défaut 1	$T_C = 0.03$ s $P_R = 100$ %	$T_C = 1.53$ s $P_R = 100$ %	$T_C = 0.03$ s $P_R = 100$ %	$T_C = 1.41$ s $P_R = 100$ %
Défaut 2	$T_C = 0.01$ s $P_R = 97.93$ %	$T_C = 1.40$ s $P_R = 97.81$ %	$T_C = 0.01$ s $P_R = 97.81$ %	$T_C = 1.42$ s $P_R = 99.98$ %
Défaut 3	$T_C = 0.06$ s $P_R = 100$ %	$T_C = 1.39$ s $P_R = 100$ %	$T_C = 0.01$ s $P_R = 100$ %	$T_C = 1.42$ s $P_R = 100$ %
Défaut 4	$T_C = 0.01$ s $P_R = 100$ %	$T_C = 1.39$ s $P_R = 100$ %	$T_C = 0.01$ s $P_R = 100$ %	$T_C = 1.41$ s $P_R = 100$ %
Défaut 5	$T_C = 0.01$ s $P_R = 100$ % $T_C = 0.01$ s $P_R = 100$ %	$T_C = 1.39$ s $P_R = 100$ % $T_C = 1.39$ s $P_R = 100$ %	$T_C = 0.01$ s $P_R = 100$ % $T_C = 0.01$ s $P_R = 100$ %	$T_C = 1.40$ s $P_R = 100$ % $T_C = 1.40$ s $P_R = 100$ %
Défaut 6	$T_C = 0.01$ s $P_R = 18.74$ %	$T_C = 1.99$ s $P_R = 97.72$ %	$T_C = 0.03$ s $P_R = 97.27$ %	$T_C = 1.94$ s $P_R = 99.98$ %
Défaut 7	$T_C = 0.01$ s $P_R = 9.13$ %	$T_C = 1.95$ s $P_R = 97.72$ %	$T_C = 0.01$ s $P_R = 97.27$ %	$T_C = 1.96$ s $P_R = 99.98$ %
Défaut 8	$T_C = 0.01$ s $P_R = 99.95$ %	$T_C = 1.90$ s $P_R = 99.95$ %	$T_C = 0.01$ s $P_R = 99.95$ %	$T_C = 1.92$ s $P_R = 99.99$ %

TABLE 3.8 – Résultats de la classification des données d'éolienne.

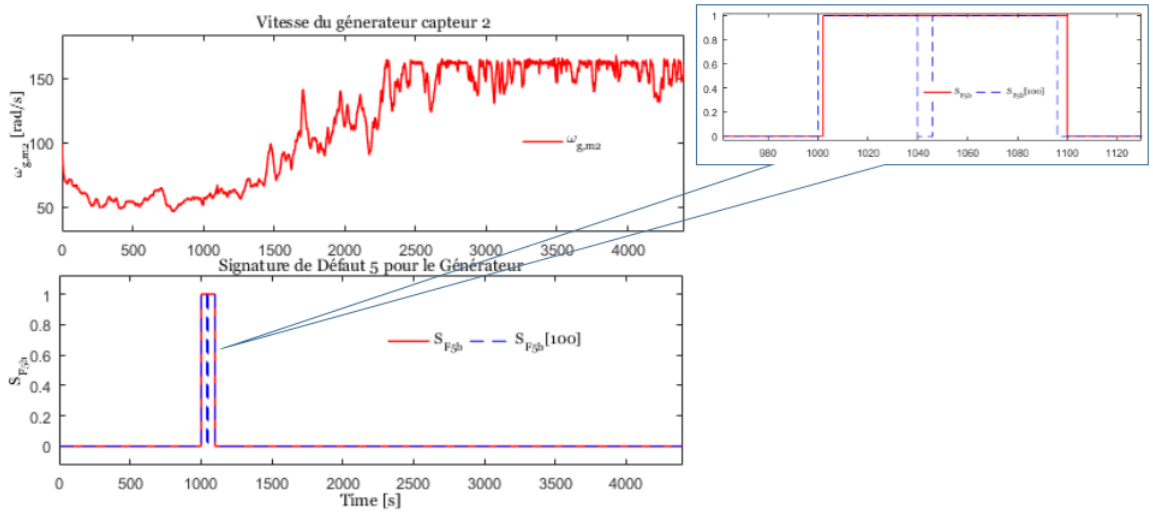


FIGURE 3.29 – Détection et isolation de défauts 5 par le classifieur adaptatif proposé pour le génerateur.

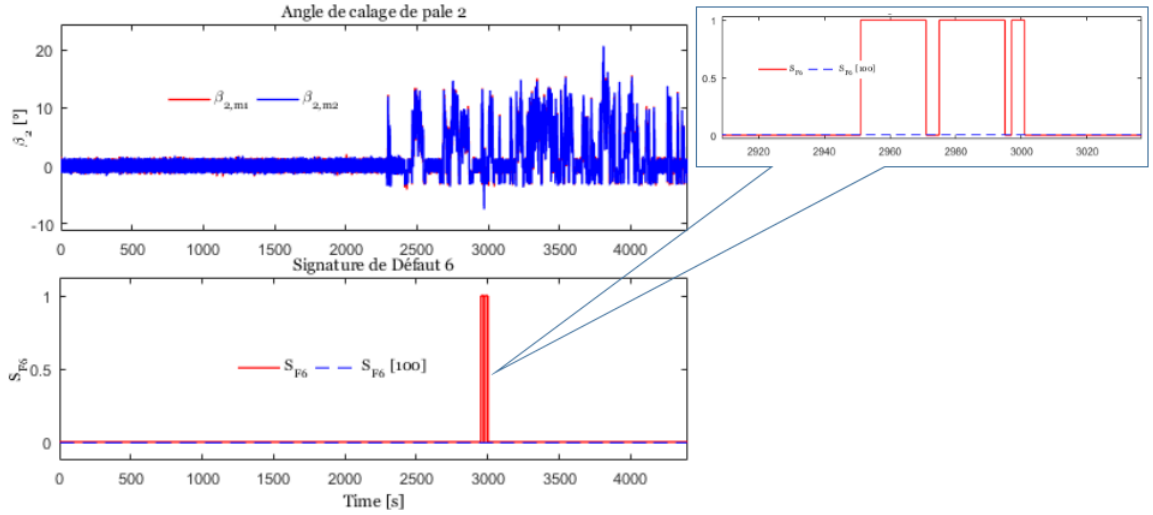


FIGURE 3.30 – Détection et isolation de défauts 6 par le classifieur adaptatif proposé.

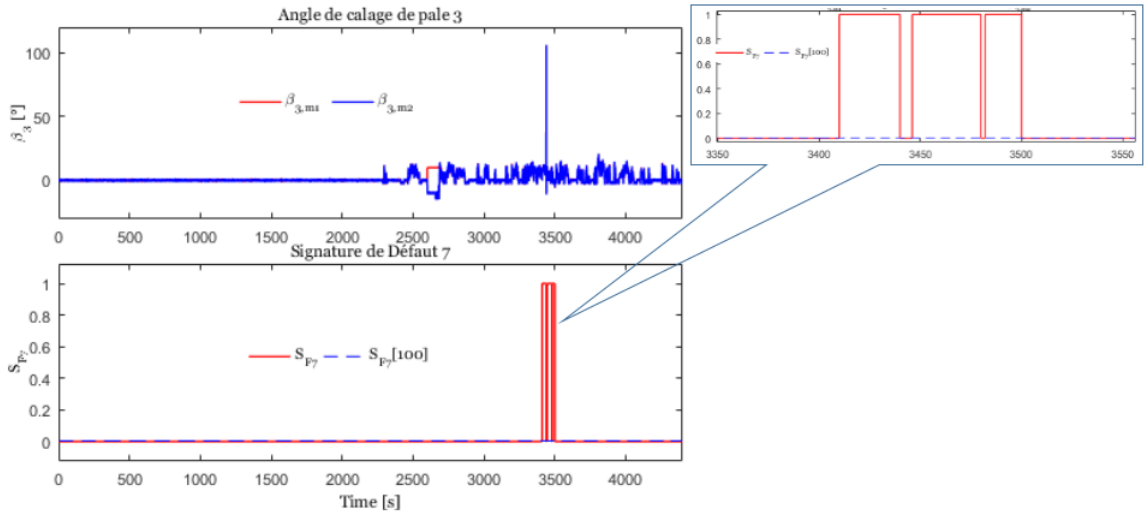


FIGURE 3.31 – Détection et isolation de défauts 7 par le classifieur adaptatif proposé.

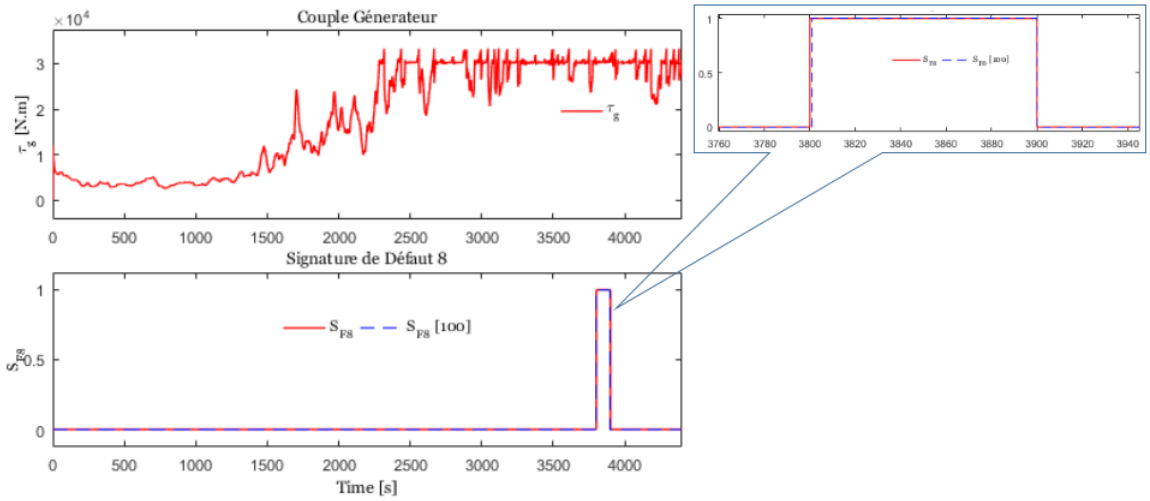


FIGURE 3.32 – Détection et isolation de défauts 8 par le classifieur adaptatif proposé.

3.4 Conclusion

Nous avons abordé le problème du diagnostic du système éolien, le premier volet de ce chapitre avait pour but de diagnostiquer l'éolienne à base de modèle : une nouvelle procédure de diagnostic active motivé par un observateur basé sur une architecture générale du système éolien et un seuil adaptatif, l'idée considérée comme un estimateur actif utilisé par la technique de diagnostic pour la détection de défaut, un ensemble d'estimateurs d'isolation de défaut, et un seuil adaptatif pour l'évaluation des résidus, tout ce fait pour déterminer le type et emplacement de défaut particulier. Le diagnostic de l'éolienne basant sur l'observateur multi intégrales proportionnelles (Proportional Multi-Intégral Observer (PMIO)) est présenté dans la deuxième partie de cette section, la modélisation du système éolien sous la forme des modèles flous affines du type Takagi-Sugeno (TS), la construction d'un contrôleur flou du type PDC pour garantir la stabilité du système, et à partir d'observateur proportionnel multi intégrales nous arrivons à estimer et isoler les différents défauts affectant le système en introduisant ainsi le bruit.

Le deuxième volet a été consacré au diagnostic du système éolien à base de données par la transformation du problème du diagnostic en un problème de classification, pour ce fait nous avons tout d'abord préparé les données sous forme des vecteurs qui portent les informations les plus pertinentes du comportement du système relatives à un défaut donné, par la suite deux classifieurs ont été développés, le premier c'est un classifieur adaptatif basé sur la technique de machine à vecteurs de support (SVM) qui est adapté par la logique floue, le deuxième classifieur proposé est basé sur une combinaison de trois approches : l'algorithme naïf bayésien ; l'approche du réseau de neurones et l'approche de l'arbre de décision.

Dans le chapitre suivant, nous proposons une approche de la commande tolérante aux défauts basée sur le principe de modèle de référence et l'algorithme d'optimisation par essaims particulaires "PSO".

Chapitre 4

Commande tolérante aux défauts pour le système éolien

Sommaire

4.1 Introduction 119

4.2 Commande tolérante aux défauts basée sur modèle de référence et l'optimisation par Essaims particulaires 'PSO' pour l'éolienne 120

4.2.1 Commande tolérante aux défauts basée sur le modèle de référence pour le système de calage de la pâle 120

4.2.2 Commande tolérante aux défauts basée sur le modèle de référence pour le générateur 123

4.2.3 Commande tolérante aux défauts basée sur le modèle de référence pour le système d'entrainement 125

4.2.4 Optimisation de la commande tolérante aux défauts proposée pour l'éolienne par la méthode d'optimisation par essaims particulaires . . 127

4.2.5 Résultats de simulations 127

4.2.6 Puissance générée 134

4.3 Conclusion 136

4.1 Introduction

Ce chapitre aborde le problème de la commande tolérante aux défauts (FTC) pour le système éolien. Motivé par la technique par modèle de référence "MRAC" et l'algorithme d'optimisation par essaims particulaires "PSO", la structure principale de cette proposition est comme un ajustement automatique de régulateur d'éolienne. Afin d'atteindre les performances système requises, même lors d'affectations des différents types de défauts et

dans les différentes composantes de système éolien, notre proposition se base sur les performances souhaitées lesquelles sont exprimées sous la forme d'un modèle de référence, dans lequel la comparaison du fonctionnement de ce modèle avec le fonctionnement du système permet d'ajuster les paramètres du contrôleur en utilisant la théorie de la stabilité de Lyapunov. De plus, la minimisation d'une fonction objective basée sur l'erreur de comparaison par le PSO permet le contrôleur proposé de converger vers un point optimal.

4.2 Commande tolérante aux défauts basée sur modèle de référence et l'optimisation par Essaims particulaires 'PSO' pour l'éolienne

Cette section consacrée à développer une nouvelle stratégie adaptative de commande tolérante aux défauts pour l'éolienne basée sur la technique de modèle de référence MRAC optimisé par une métaheuristique d'optimisation appelée l'optimisation par Essaims particulaires (OEP ou Particules swarm Optimisation PSO en anglais) comme illustre la figure 4.1. L'idée est de construire un contrôleur adaptatif dans lequel les performances souhaitées sont exprimées en matière de modèle de référence sans bruit et sans défaillance, l'erreur de comparaison entre le modèle de référence et le système est la base du mécanisme d'ajustement des paramètres du contrôleur [**105**]. Et avec l'application de la théorie de la stabilité du Lyapunov, nous avons déterminé les paramètres de contrôleur, en particulier pour le système de calage de la pâle, pour le système générateur et ainsi pour le système d'entraînement d'éolienne. De plus, la minimisation d'une fonction objective basée sur cet erreur de comparaison, permet à travers l'algorithme PSO d'obtenir les paramètres de contrôle optimaux qui bénéficient plus de performances de qualité de conversion d'énergie de l'éolienne.

4.2.1 Commande tolérante aux défauts basée sur le modèle de référence pour le système de calage de la pâle

Dans cette partie, l'approche de commande par modèle de référence a été appliquée au système actionneur de calage de la pâle en utilisant la règle du MIT [**105**]. Puisque le système de second ordre sous amorti est de nature oscillatoire, alors si les oscillations ne

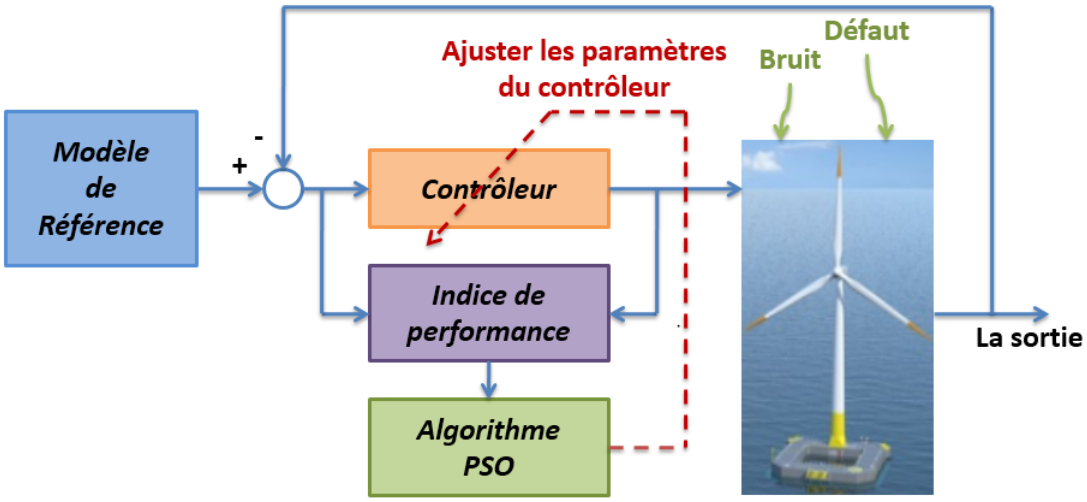


FIGURE 4.1 – Structure globale du FTC proposée.

se désintègrent pas sur une période de temps limitée, elles peuvent alors provoquer une instabilité du système. Ainsi, pour un fonctionnement stable, un dépassement maximal doit être aussi faible que possible (idéalement nul), ce qui peut réduire automatiquement la période transitoire de système et améliorer leurs performances. le système de calage de la pâle est présenté comme un système du second ordre (2.17) avec un temps de stabilisation plus long. L'objective de cette étude est d'améliorer les performances de ce système même en présence d'un bruit et d'un défaut, alors pour atteindre cette objective nous avons utilisé un schéma de contrôle adaptatif.

Décrivons le système de calage de la pâle à partir d'équation (2.17) :

$$G(s) = \frac{Y(s)}{U(s)} = \frac{w_n^2}{s^2 + 2 \cdot \zeta \cdot w_n \cdot s + w_n^2} = \frac{N}{D} \tag{4.1}$$

Où $Y(s)$ est la sortie du système de calage de la pâle, c'est-à-dire l'angle de calage de la pâle mesuré $\beta_i(s)$ et $U(s)$ est la loi de commande ou la variable à manipuler, c'est-à-dire l'angle de calage de la pâle désiré $\beta_{i,ref}(s)$.

De même façons, le modèle de référence est décrit par :

$$G_m(s) = \frac{Y_m(s)}{U_c(s)} = \frac{w_n^2}{s^2 + 2 \cdot \zeta \cdot w_n \cdot s + w_n^2} \tag{4.2}$$

Où $Y_m(s)$ est la sortie de modèle de référence du système de calage de la pâle, c'est-à-dire

l'angle de calage de la pâle mesuré pour le modèle de référence $(\beta_{i_m})(s)$ et $U_c(s)$ est la loi de commande ou la variable à manipuler pour le modèle de référence, c'est-à-dire l'angle de calage de la pâle désiré pour le modèle de référence $(\beta_{i,ref_c})(s)$.

Alors, l'objetif de la technique de commande MRAC est de minimiser l'erreur entre la sortie réelle $Y(s)$ et la sortie de modèle de référence $Y_m(s)$. Afin d'améliorer le rendement global en présence du bruit et des défauts, nous avons proposé la loi de contrôle sous la forme d'un filtre passe bas suivant :

$$U(s) = \frac{t_0}{1 + r_0 \cdot s} U_c(s) - \frac{s_0}{1 + r_0 \cdot s} Y(s) \tag{4.3}$$

Par substitution d'équation (4.3) dans l'équation (4.1), nous obtenons :

$$Y(s) = \frac{t_0}{1 + r_0 \cdot s} \frac{N}{D} U_c(s) - \frac{s_0}{1 + r_0 \cdot s} \frac{N}{D} Y(s) \tag{4.4}$$

Ce qui donne :

$$\frac{Y(s)}{U_c(s)} = \frac{N t_0}{D(1 + r_0 \cdot s) + s_0 N} \tag{4.5}$$

À partir de l'équation d'erreur :

$$e(t) = y(t) - y_m(t) \tag{4.6}$$

La dynamique d'erreur en fonction de chaque paramètre du contrôleur :

$$\frac{\partial e}{\partial t_0} = \frac{N}{D(1 + r_0 s) + s_0 N} U_c \approx G_m U_c \tag{4.7}$$

$$\frac{\partial e}{\partial s_0} = \frac{-N^2}{[D(1 + r_0 \cdot s) + s_0 N]^2} U_c \approx -G_m Y \tag{4.8}$$

$$\frac{\partial e}{\partial r_0} = \frac{-N D s}{[D(1 + r_0 \cdot s) + s_0 N]^2} U_c \approx -G_m U_c \tag{4.9}$$

De l'équation (1.4) avec γ est un scalaire positif, nous obtenons :

$$\frac{\partial t_0}{\partial t} = -\gamma_{Bi1} [G_m \cdot U_c] e \underset{\Longrightarrow}{\int} t_0 = -\frac{\gamma_{Bi1}}{s} [G_m \cdot U_c] e \tag{4.10}$$

$$\frac{\partial s_0}{\partial t} = \gamma_{Bi2} [G_m \cdot Y] e \underset{\Longrightarrow}{\int} s_0 = \frac{\gamma_{Bi2}}{s} [G_m Y] e \tag{4.11}$$

$$\frac{\partial r_0}{\partial t} = \gamma_{Bi3}[G_m \cdot U_c]e \underset{\Longrightarrow}{\int} r_0 = \frac{\gamma_{Bi3}}{s}[G_m \cdot U_c]e \tag{4.12}$$

Avec γ_{Bi1}, γ_{Bi2} et γ_{Bi3} sont des scalaires positifs.

Donc, lorsqu'on remplace les paramteres t_0, s_0 et r_0 dans la loi de commande proposée en (4.3), on trouve la commande appliquée au système de calage de la pâle.

4.2.2 Commande tolérante aux défauts basée sur le modèle de référence pour le générateur

Dans cette partie l'approche de commande MRAC est appliquée au système générateur, l'application de cette approche conçu à l'aide de la règle MIT [**105**]. Le système générateur est très sensible aux changements dus à la grande amplitude de l'entrée désirée du couple génerateur $\tau_{g,r}$, ce qui ramène ce système à l'instabilité. Afin d'éviter ce problème, l'algorithme normalisé a été utilisé par la règle du MIT pour développer un contrôleur sous la forme d'un filtre passe bas pour ce système de générateur.

Décrivons le système du générateur à partir d'équation (2.19) :

$$H(s) = \frac{Y(s)}{U(s)} = \frac{\tau_g(s)}{\tau_{g,r}(s)} = \frac{\alpha_{gc}}{s + \alpha_{gc}} = \frac{M}{T} \tag{4.13}$$

Où $Y(s)$ est la sortie de système générateur, c'est-à-dire le couple générateur $\tau_g(s)$ et $U(s)$ est l'entrée de commande pour le système générateur, c'est-à-dire le couple générateur désiré $\tau_{g,r}(s)$.

De même structure, le modèle de référence est décrit par :

$$H_m(s) = \frac{Y_m(s)}{U_c(s)} = \frac{\tau_{g_m}(s)}{\tau_{g,r_c}(s)} = \frac{\alpha_{gc_m}}{s + \alpha_{gc_m}} \tag{4.14}$$

Où $Y_m(s)$ est la sortie de modèle de référence du système générateur, c'est-à-dire le couple générateur $\tau_{g_m}(s)$ et $U(s)$ est l'entrée de commande pour le modèle de référence du système générateur, c'est-à-dire le couple générateur désiré $\tau_{g,r_c}(s)$.

Alors, notre objetive est de minimiser l'erreur entre la sortie réelle $Y(s)$ et la sortie de modèle de référence $Y_m(s)$ (modèle idéal sans bruit sans défaut) par l'application de schéma du commande adaptative MRAC basé sur modèle de référence. Afin d'améliorer le

rendement global même en présence de bruit et des défauts, nous avons proposé la loi de contrôle sous la forme d'un filtre passe bas suivant :

$$U(s) = \frac{t_1}{1 + r_1 \cdot s} U_c(s) - \frac{s_1}{1 + r_1 \cdot s} Y(s) \tag{4.15}$$

Par substitution de l'équation (4.15) dans l'équation (4.13), nous obtenons :

$$Y(s) = \frac{t_1}{1 + r_1 \cdot s} \frac{M}{T} U_c(s) - \frac{s_1}{1 + r_1 \cdot s} \frac{M}{T} Y(s) \tag{4.16}$$

Cequi donne :

$$\frac{Y(s)}{U_c(s)} = \frac{M t_1}{T(1 + r_1 \cdot s) + s_1 M} \tag{4.17}$$

À partir de l'équation d'erreur (4.6), la dynamique d'erreur concernant en fonction de chaque paramètre du contrôleur :

$$\frac{\partial e}{\partial t_1} = \frac{M}{T(1 + r_1 \cdot s) + s_1 M} U_c \approx H_m U_c \tag{4.18}$$

$$\frac{\partial e}{\partial s_1} = \frac{-M^2}{[T(1 + r_1 \cdot s) + s_1 M]^2} U_c \approx -H_m Y \tag{4.19}$$

$$\frac{\partial e}{\partial r_1} = \frac{-M \cdot T \cdot s}{[T(1 + r_1 \cdot s) + s_1 M]^2} U_c \approx -H_m U_c \tag{4.20}$$

De l'équation (1.4) avec γ est un scalaire positif, nous obtenons :

$$\frac{\partial t_1}{\partial t} = -\gamma_{G1} [H_m \cdot U_c] e \underset{\Longrightarrow}{\int} t_1 = -\frac{\gamma_{G1}}{s} [H_m \cdot U_c] e \tag{4.21}$$

$$\frac{\partial s_1}{\partial t} = \gamma_{G2} [H_m \cdot Y] e \underset{\Longrightarrow}{\int} s_1 = \frac{\gamma_{G2}}{s} [H_m \cdot Y] e \tag{4.22}$$

$$\frac{\partial r_1}{\partial t} = \gamma_{G3} [H_m \cdot U_c] e \underset{\Longrightarrow}{\int} r_1 = \frac{\gamma_{G3}}{s} [H_m \cdot U_c] e \tag{4.23}$$

Avec γ_{G1}, γ_{G2} et γ_{G3} sont des scalaires positifs.

Donc, lorsqu'on remplace les paramteres t_1, s_1 et r_1 dans la loi de commande proposée en (4.15), on trouve la commande appliquée au système de générateur.

4.2.3 Commande tolérante aux défauts basée sur le modèle de référence pour le système d'entrainement

Dans cette partie, une conception d'un contrôleur adaptatif par l'application de la théorie de la stabilité du Lyapunov pour le système d'entrainement [**105**]. Par conséquent, nous avons définit la dynamique de l'erreur entre le système et le modèle de référence : $e = y - y_m$ pour determiner les paramètres de contrôleur. Par la suite nous avons développé un mécanisme d'adaptation pour adapter les paramètres de contrôleur par l'application de la théorie de Lyapunov de stabilité [**107**]-[**108**].

Le système d'entrainement est le responsable de réglage de la vitesse de rotation du rotor et du générateur est c'est lui qui permet d'élever ces vitesses de rotation pour améliorer le rendement de conversion d'éolienne. Le modèle de système d'entrainement comprend des arbres à vitesse lente et élevée reliée entre eux par une boîte de vitesses conçue comme un rapport de vitesses. Par conséquent, le modèle sous forme d'une représentation d'état du système d'entrainement est donné dans l'équation (2.25) sous la forme suivante :

$$Processus : \dot{x}(t) = A \cdot x(t) + B \cdot u(t) \tag{4.24}$$

$$Modèle\,de\,référence : \dot{x}_m(t) = A_m \cdot x_m(t) + B_m \cdot u_c(t) \tag{4.25}$$

Où $x(t) = [\ \omega_r(t) \quad \omega_g(t) \quad \theta_\Delta(t)\ ]^T$, $u(t) = [\ \tau_r(t) \quad \tau_g(t)\ ]^T$, et de même pour le modèle de référence $x_m(t) = [\ \omega_{r_m}(t) \quad \omega_{g_m}(t) \quad \theta_{\Delta_m}(t)\ ]^T$, $u_c(t) = [\ \tau_{r_c}(t) \quad \tau_{g_c}(t)\ ]^T$.

Dans cette étude on considère la loi de commande suivante :

$$u(t) = M \cdot u_c(t) - L \cdot x(t) \tag{4.26}$$

Avec : $L = \begin{bmatrix} L_1 \\ L_2 \end{bmatrix}$; $L_1 = \begin{bmatrix} l_{11} & l_{12} & l_{13} \end{bmatrix}$; $L_2 = \begin{bmatrix} l_{21} & l_{22} & l_{23} \end{bmatrix}$;

Et $M = \begin{bmatrix} M_1 \\ M_2 \end{bmatrix}$; $M_1 = \begin{bmatrix} m_{11} & m_{12} \end{bmatrix}$; $M_2 = \begin{bmatrix} m_{21} & m_{22} \end{bmatrix}$.

Le signal d'erreur est présenté pour cette étude comme suit :

$$e(t) = x(t) - x_m(t) \tag{4.27}$$

Alors la dynamique de l'erreur est la suivante :

$$\dot{e}(t) = \frac{de(t)}{dt} = \dot{x}(t) - \dot{x}_m(t) \tag{4.28}$$

Ce qui devient :

$$\dot{e}(t) = A \cdot x(t) + B \cdot u(t) - A_m \cdot x_m(t) - B_m \cdot u_c(t)$$
$$\dot{e}(t) = A_m \cdot e(t) + (A - A_m - BL) \cdot x(t) + (BM - B_m) \cdot u_c(t)$$

Pour simplifier cette formule on peut reécrire :

$$\dot{e}(t) = A_m \cdot e(t) + \Psi(x, u_c)(\Theta - \Theta^0) \tag{4.29}$$

Considérons la fonction de Lyapunov suivante :

$$V(t) = \frac{1}{2}[e^T(t) \cdot P \cdot e(t) + \frac{1}{\gamma}(\Theta - \Theta^0)^T(\Theta - \Theta^0)] \tag{4.30}$$

Où $P = P^T > 0$ et $\gamma > 0$.

La dérivée de la fonction de Lyapunov $V(t)$ en fonction du temps est :

$$\dot{V}(t) = \frac{1}{2}e^T(t)[PA_m + A_m^T P]e(t) + (\Theta - \Theta^0)^T \Psi(x, u_c) P e(t) + \frac{1}{\gamma}(\Theta - \Theta^0)^T \dot{\Theta} \tag{4.31}$$

On peut remplacer le premier terme par $-Q$ avec $Q > 0$ puisque :

$$PA_m + A_m^T P = -Q \tag{4.32}$$

Et nous choisissons la loi d'ajustement comme :

$$\dot{\Theta} = -\gamma \Psi^T(x, u_c) \cdot P \cdot e = -\gamma \Psi^T(x, u_c) \cdot P \cdot (x(t) - x_m(t)) \tag{4.33}$$

Avec $\Psi(x, u_c) = [\ -x \quad -\dot{x} \quad u_c \quad \dot{u}_c\ ]$ et $\Theta = [\ L_1^T \quad L_2^T \quad M_1^T \quad M_2^T\ ]^T$.

Donc :

$$\dot{\Theta} = \begin{bmatrix} \dot{L}_1^T \\ \dot{L}_2^T \\ \dot{M}_1^T \\ \dot{M}_2^T \end{bmatrix} = \begin{bmatrix} \gamma_{DT1} x e \\ \gamma_{DT2} \dot{x} e \\ -\gamma_{DT3} u_c e \\ -\gamma_{DT4} \dot{u}_c e \end{bmatrix} \tag{4.34}$$

À partir d'integration d'équation (4.34), on obtient :

$$\Theta = \begin{bmatrix} L_1^T \\ L_2^T \\ M_1^T \\ M_2^T \end{bmatrix} = \begin{bmatrix} \frac{\gamma_{DT1}}{s} \cdot x \cdot e \\ \frac{\gamma_{DT2}}{s} \cdot \dot{x} \cdot e \\ -\frac{\gamma_{DT3}}{s} \cdot u_c \cdot e \\ -\frac{\gamma_{DT4}}{s} \dot{u}_c \cdot e \end{bmatrix} \tag{4.35}$$

Par substituant de (4.32) et (4.33) dans (4.31), nous obtenons le dérivé de la fonction de Lyapunov $\dot{V}(t)$ définit négatif comme suit :

$$\dot{V}(t) = \frac{1}{2} e^T(t) \cdot Q \cdot e(t) < 0 \tag{4.36}$$

Finalement puisque $\dot{V}(t) < 0$, on peut garantis que l'erreur doit $e(t)$ converger vers zéro : $e(t) \longrightarrow 0$ en appliquant la théorie de Lyapunov.

4.2.4 Optimisation de la commande tolérante aux défauts proposée pour l'éolienne par la méthode d'optimisation par essaims particulaires

Dans cette partie, nous utilisons donc la méthode d'optimisation par essaims particulaires pour optimiser les paramètres de contrôleur γ_i proposé dans les trois parties précédentes du système éolien. Pour cette raison, la fonction objective proposée $f(e)$ pour le fonctionnement de cet algorithme d'optimisation est en fonction de l'erreur de poursuite entre le modèle de référence et le système, comme présenté ci-dessous :

$$f(e) = \int e(t)dt \tag{4.37}$$

4.2.5 Résultats de simulations

Le contrôleur d'éolienne utilisé dans ce travail dans deux régions est présenté à la section (2.4.4) dans le deuxième chapitre. La région 2 est désignée pour l'optimisation de la puissance, et la région 3 correspond à la saturation. Le contrôleur est mis en œuvre avec une fréquence d'échantillonnage de $100Hz$. Le contrôleur démarre en mode 1, la Figure 2.7 montre l'évolution de vitesse du vent $\nu_\omega(t)$ proposé dans une séquence temps pour ce

modèle d'éolienne (l'entrée). Toutes les simulations suivantes sont effectuées pendant une séquence du temps de $4400s$, avec les paramètres du système éolien sont présentées dans le tableau 2.1 et les défauts proposés sont présentés dans le tableau 3.1. Par la suite nous traitons et discutons chaque partie d'éolienne séparément :

4.2.5.1 Commande tolérante aux défauts pour le système de calage de la pâle

Commande tolérante aux défauts pour le système de calage de la pâle 1 : Dans cette première partie, nous discutons le premier système de calage de la pâle d'éolienne afin d'obtenir un contrôleur optimal. Pour cette raison, les paramètres γ_{B11}, γ_{B12} et γ_{B13} de contrôleur proposé sont optimisés par la méthode d'optimisation par essaims particulaires PSO en minimisant la fonction objective (4.37). Selon la technique de commande MRAC développé précédemment, après avoir substitué les paramètres du contrôleur dans les équations (4.10), (4.11) et (4.12), nous obtenons la loi de commande proposée définie dans l'équation (4.3), où $u_c(t) = \beta_r(t) = 0°$ et $y(t) = 1/2 * (\beta_{1,m1}(t) + \beta_{1,m2}(t))$, la Figure 4.2 montre l'évolution de la commande FTC proposée dans le temps pour système d'actionneur de calage de la pâle. La variation des paramètres de contrôleur optimisé par la la méthode d'optimisation par essaims particulaires PSO converge vers un point optimal, présenté dans le tableau 4.1.

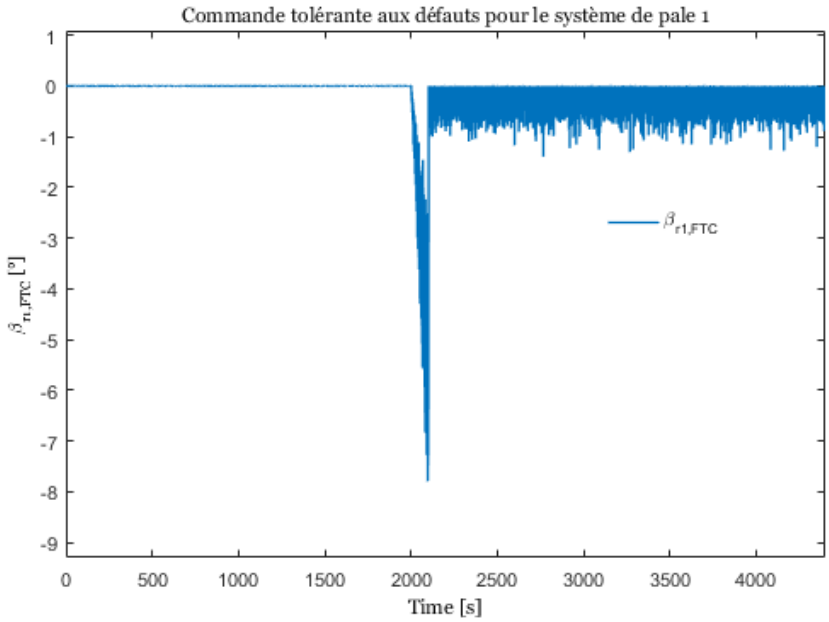


FIGURE 4.2 – Commande tolérante aux défauts proposée pour le système de la pâle 1.

Commande tolérante aux défauts pour le système de calage de la pâle 2 : Dans cette seconde partie, nous discutons le deuxième système de calage de la pâle d'éolienne afin d'obtenir un contrôleur optimal. Pour cette raison, les paramètres γ_{B21}, γ_{B22} et γ_{B23} de contrôleur proposé sont optimisés par la méthode d'optimisation par essaims particulaires PSO en minimisant la fonction objective (4.37). Selon la technique de commande MRAC développé précédement, après avoir substitué les paramètres du contrôleur dans les équations (4.10), (4.11) et (4.12), nous obtenons la loi de commande proposée définie dans l'équation (4.3), où $u_c(t) = \beta_r(t) = 0°$ et $y(t) = 1/2 * (\beta_{2,m1}(t) + \beta_{2,m2}(t))$, la Figure 4.3 montre l'évolution de la commande FTC proposée dans le temps pour système d'actionneur de calage de la pâle 2. La variation des paramètres de contrôleur optimisé par la la méthode d'optimisation par essaims particulaires PSO converge vers un point optimal, présenté dans le tableau 4.1.

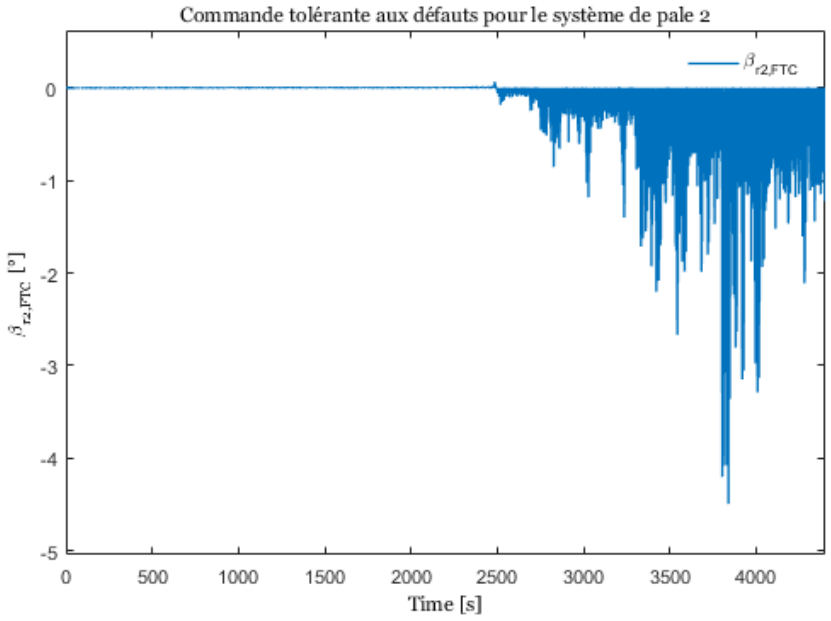


FIGURE 4.3 – Commande tolérante aux défauts proposée pour le système de la pâle 2.

Commande tolérante aux défauts pour le système de calage de la pâle 3 : Dans cette troisième partie, nous discutons le troisième système de calage de la pâle d'éolienne afin d'obtenir un contrôleur optimal. Pour cette raison, les paramètres γ_{B31}, γ_{B32} et γ_{B33} de contrôleur proposé sont optimisés par la méthode d'optimisation par essaims particulaires PSO en minimisant la fonction objective (4.37). Selon la technique de commande MRAC développé précédement, après avoir substitué les paramètres du contrôleur dans les équations (4.10), (4.11) et (4.12), nous obtenons la loi de commande proposée définie

dans l'équation (4.3), où $u_c(t) = \beta_r(t) = 0°$ et $y(t) = 1/2 * (\beta_{3,m1}(t) + \beta_{3,m2}(t))$. La Figure 4.4 montre l'évolution de la commande FTC proposée dans le temps pour système d'actionneur de calage de la pâle 3. La variation des paramètres de contrôleur optimisé par la la méthode d'optimisation par essaims particulaires PSO converge vers un point optimal, présenté dans le tableau 4.1.

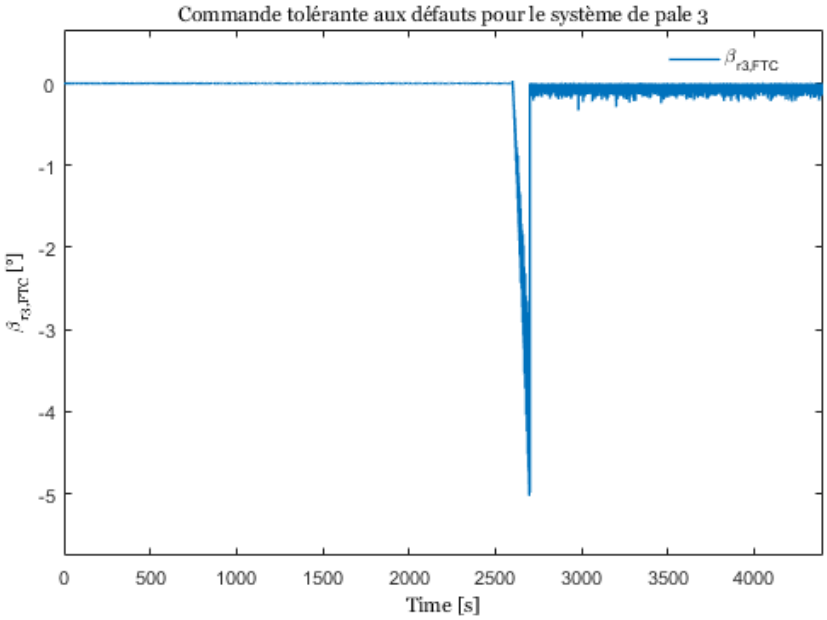


FIGURE 4.4 – Commande tolérante aux défauts proposée pour le système de pâle 3.

Puisque le système de calage de la pâle a été exprimé par un modèle linéaire du second ordre, la réponse varie selon un système de second ordre suramorti, amorti de façon critique ou bien sous amorti. De plus, le bruit et les défauts peuvent causer une instabilité du système. Donc, pour garantir leur stabilité, nous avons considéré un système de commande en boucle fermée basé sur la règle MIT [**105**] dans laquelle nous avons ajusté les paramètres du contrôleur. La réponse en boucle fermée souhaitée est présentée par un modèle de référence dont la sortie est y_m. Par conséquent, e est l'erreur entre la sortie du système en boucle fermée y et la sortie du modèle de référence y_m. Une possibilité consiste à ajuster les paramètres de manière à minimiser la fonction de perte $J(\theta) = \frac{1}{2}e^2$, comme expliqué dans [**105**]. En outre, la loi de commande proposée est exprimé sous la forme d'un filtre passe bas présenté dans l'équation (4.3), puis l'algorithme d'optimisation par essaims particulaires PSO permettant d'optimiser les paramètres de contrôleur MRAC lorsque nous minimisons la fonction objective (4.37). En conséquence, le contrôleur commence à entraîner l'éolienne à proximité de son fonctionnement optimal, ce qui se traduira par un

rendement de conversion d'énergie électrique élevé. Cependant, dans les approches FTC appliqué au système éolien comme dans [**82**], lequels la présence du bruit et des défauts minimise la qualité de la conversion d'énergie et diminue la quantité d'énergie électrique générée par l'éolienne, dans la mesure où le contrôleur démarre loin de fonctionnement optimal de l'éolienne, ce qui réduit l'efficacité de conversion comme indiqué dans la figure (4.8) qui exprime la puissance de sortie générée par l'éolienne.

4.2.5.2 Commande tolérante aux défauts pour le système générateur

Dans cette partie, le système générateur de l'éolienne a été développé afin d'obtenir un contrôle optimal. Pour cette raison, les paramètres γ_{G1}, γ_{G2} et γ_{G3} du contrôleur sont optimisés par l'algorithme d'optimisation par essaims particulaires PSO en minimisant la fonction objective présentée dans l'équation (4.37). La substitution de paramètres de contrôleur obtenus dans les équations (4.21), (4.22) et (4.23), permet d'obtenir la loi de commande proposée définie dans (4.15), où $u_c(t) = \tau_{g,r}(t)$ et $y(t) = 1/2*(\tau_{g,m1}(t)+\tau_{g,m2}(t))$. La figure 4.5 montre l'évolution du contrôle proposé dans le temps du système générateur. La variation des paramètres de contrôleur optimisé par la la méthode d'optimisation par essaims particulaires PSO converge vers un point optimal, présenté dans le tableau 4.1.

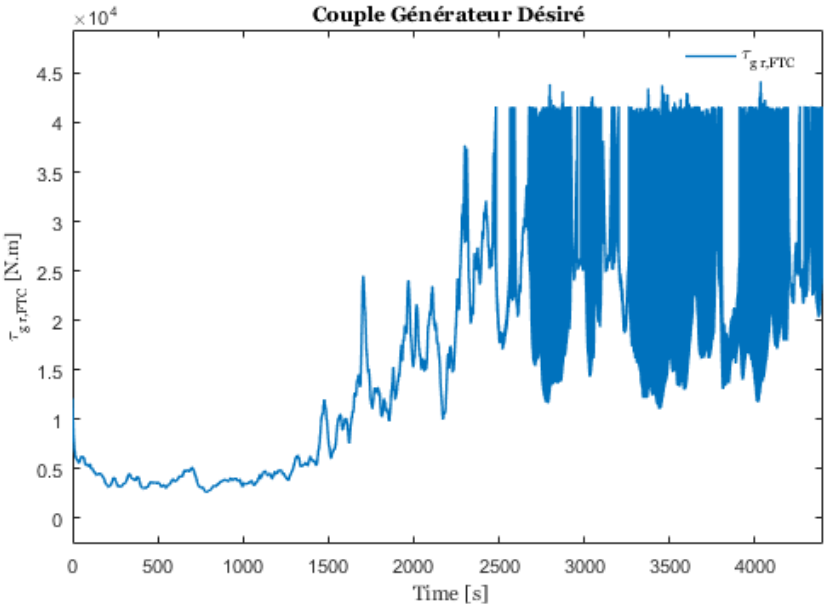


FIGURE 4.5 – Commande tolérante aux défauts proposée pour le système générateur : Couple générateur désiré.

Le modèle générateur de système éolien est présenté comme une fonction de transfert de premier ordre (2.19). Ce modèle est très sensible aux changements dus à la grande amplitude de l'entrée de référence ($\tau_{g,r}(t)$), au bruit et au défaut qui peut affecter le système, ce qui cause une instabilité. Donc, pour garantie leur stabilité, nous avons développé un système de commande adaptatif basé sur la règle du MIT, le système de commande MRAC en boucle fermée dispose les paramètres ajustables θ [**105**]. Le modéle de référence présente la réponse en boucle fermée souhaitée dont la sortie est y_m. Par conséquent, e est l'erreur de poursuite entre la sortie du système en boucle fermée y et la sortie du modèle y_m. Une possibilité consiste à ajuster les paramètres de manière à minimiser la fonction de perte $J(\theta) = \frac{1}{2}e^2$, comme expliqué dans [**106**]. En outre, la loi de commande proposée est exprimée sous la forme d'un filtre passe-bas présenté dans l'équation (4.15) et la technique d'optimisation par essaims particulaires PSO permettant d'optimiser les paramètres de contrôleur proposé, en minimisant la fonction objective (4.37). En conséquence, le contrôleur commence à entraîner l'éolienne à proximité de son fonctionnement optimal, ce qui se traduira par un rendement de conversion d'énergie électrique élevé. Cependant, dans les approches FTC appliqué à l'éolienne comme dans [**82**], lequels la présence du bruit et des défauts minimise la qualité de la conversion d'énergie et diminue la quantité d'énergie électrique générée par l'éolienne, dans la mesure où le contrôleur démarre loin de fonctionnement optimal de l'éolienne, ce qui réduit l'efficacité de conversion comme indiqué dans la figure (4.8) qui exprime la puissance de sortie générée par l'éolienne.

4.2.5.3 Commande tolérante aux défauts pour le système d'entrainement

Dans cette partie, le système d'entrainement de l'éolienne a été développé afin d'obtenir un contrôle optimal. Toutefois, les paramètres γ_{DT1}, γ_{DT2}, γ_{DT3} et γ_{DT4} du contrôleur sont optimisés par l'application de la technique d'optimisation par essaims particulaires PSO en minimisant la fonction objective présentée dans l'équation (4.37). La substitution des paramètres de contrôleur (4.35) dans la loi de commande présenté à l'équation (4.26), où : $u_c(t) = \left[\begin{array}{cc} \frac{(\tau_{r,m1}(t)+\tau_{r,m2}(t))}{2} & \frac{(\tau_{g,m1}(t)+\tau_{g,m2}(t))}{2} \end{array} \right]^T$ et $x(t) = \left[\begin{array}{ccc} \frac{(\omega_{r,m1}(t)+\omega_{r,m2}(t))}{2} & \frac{(\omega_{g,m1}(t)+\omega_{g,m2}(t))}{2} & \theta_\Delta(t) \end{array} \right]^T$, permet de définit la commande appliquée. Les figures 4.6 et 4.7 indiquent l'évolution de la commande proposée en fonction du temps. La variation des paramètres de contrôleur optimisé par la la méthode d'optimisation par essaims particulaires PSO converge vers un point optimal, présenté dans le tableau 4.1.

Le modèle du système d'entrainement à deux masses présentée dans la représentation

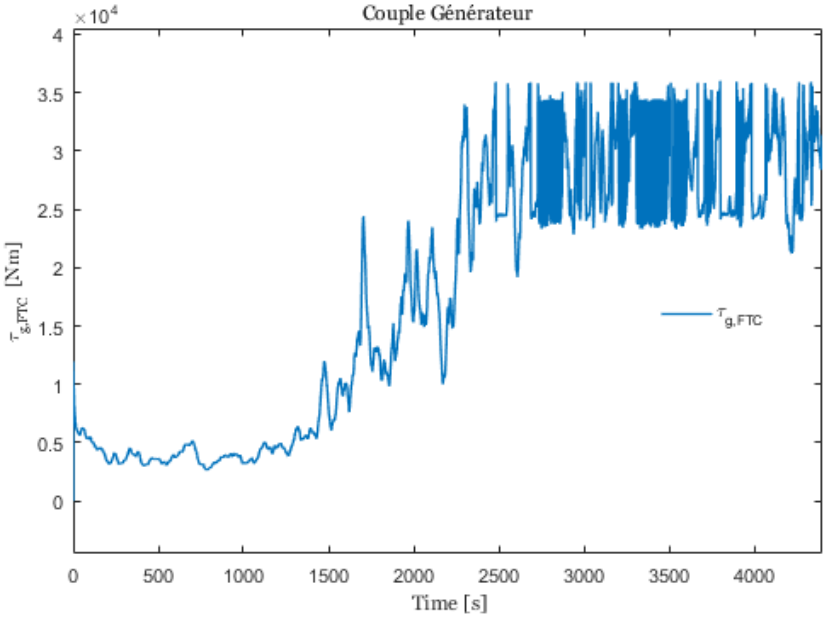


FIGURE 4.6 – Commande tolérante aux défauts proposée pour le système d'entrainement : Couple générateur.

d'états (2.25), ce modèle est le responsable de l'adaptation de la vitesse de rotation du rotor à une vitesse rationnelle à une haute génération. Puisque la puissance électrique générée par l'éolienne est directement liée à la sortie du système d'entrainement, nous avons donc besoin d'un contrôleur robuste pour ce système. Pour cette raison, la stabilité basée sur la théorie du Lyapunov est proposée pour construire un contrôleur adaptatif au système d'entrainement. Pour cette raison, nous définissons la dynamique d'erreur $e(t)$ de poursuite, qui est contient les paramètres ajustables de contrôleur, nous avons ensuite tenté de trouver une fonction de Lyapunov $V(t)$ (voir l'équation (4.30)) pour obtenir un mécanisme adaptatif de contrôle qui satisfait de plus la stabilité de système [**106**], bien que nous avons optimisé les paramètres du contrôleur en se basant sur l'algorithme d'optimisation par essaims particulaires PSO en minimisant la fonction objective (4.37), ce qui ramène l'erreur entre le système et leur modèle de référence converge donc à zéro. Par conséquent, le contrôleur commence à entraîner l'éolienne à proximité de son fonctionnement optimal, ce qui se traduira par un rendement de conversion d'énergie électrique élevé. Cependant, dans les approches FTC appliqué à l'éolienne comme dans [**82**] et [**105**], lequels la présence du bruit et des défauts minimise la qualité de la conversion d'énergie et diminue la quantité d'énergie électrique générée par l'éolienne, dans la mesure où le contrôleur démarre loin de fonctionnement optimal de l'éolienne, ce qui réduit l'efficacité de conversion comme indiqué dans la figure (4.8) qui exprime la puissance de sortie générée par l'éolienne.

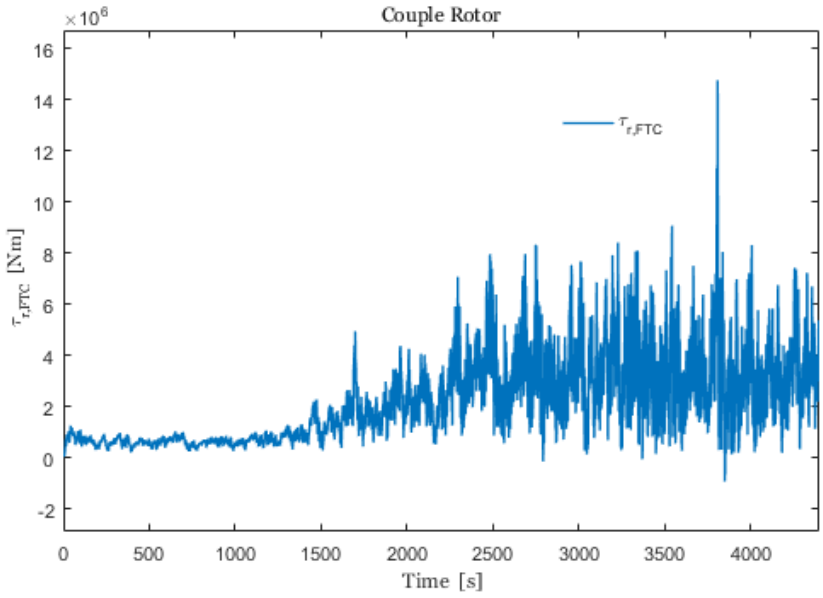


FIGURE 4.7 – Commande tolérante aux défauts proposée pour le système d'entrainement : Couple rotor.

4.2.6 Puissance générée

Pour bénéficier la stabilité, la fiabilité et la sécurité d'un système éolien même en présence de bruit et des défauts dans les différentes parties du système comme présenté dans le tableau 3.1. Nous avons appliqué les contrôleurs optimaux proposés précédement : $\beta_{r1_{FTC}}(t)$, $\beta_{r2_{FTC}}(t)$, $\beta_{r3_{FTC}}(t)$, $\tau_{g,r_{FTC}}(t)$, $\tau_{g_{FTC}}(t)$ et $\tau_{r_{FTC}}(t)$, ce qui permet d'entraîner l'éolienne à proximité de son fonctionnement optimal. La comparaison de la puissance générée par l'éolienne présenté dans la figure 4.8 illustre l'éfficacité de notre proposition par rapport aux approches de FTC [**82**] et [**105**].

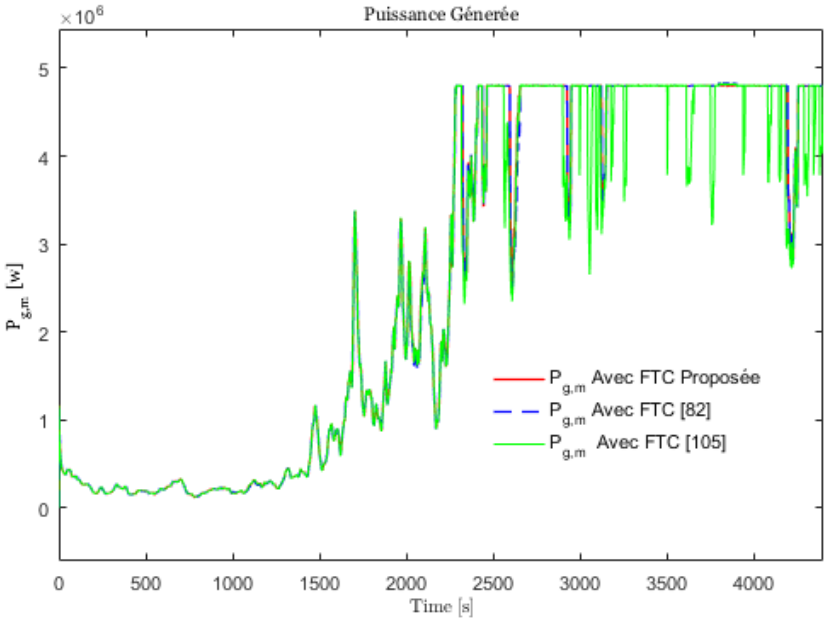
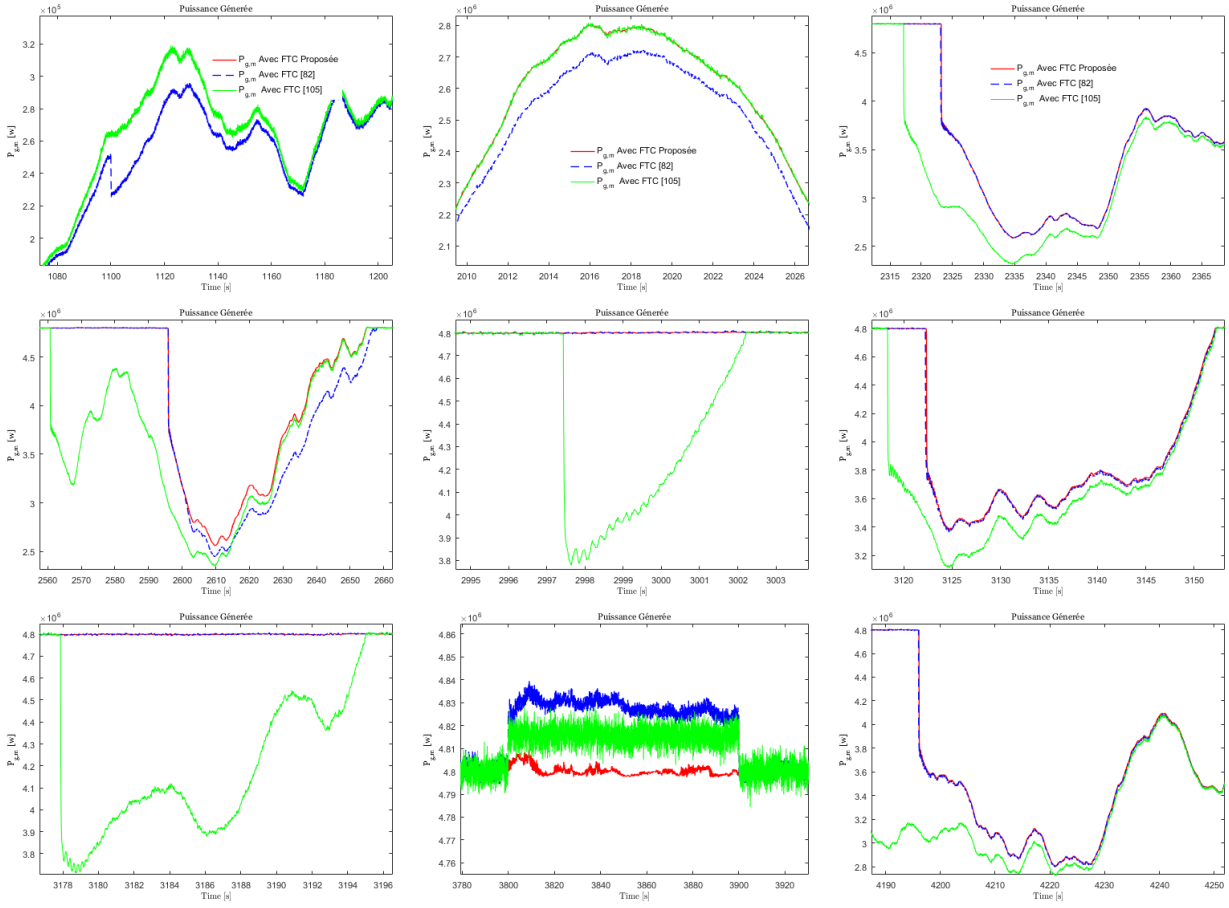


FIGURE 4.8 – Puissance générée $P_{g,m}$.



Description des Paramètres	Valeurs des Paramètres
Système de la Pâle 1	$\gamma_{B11} = 330$ $\gamma_{B12} = 460$ $\gamma_{B13} = 156$
Système de la Pâle 2	$\gamma_{B21} = 370$ $\gamma_{B22} = 482$ $\gamma_{B23} = 193$
Système de la Pâle 3	$\gamma_{B31} = 336$ $\gamma_{B32} = 475$ $\gamma_{B33} = 163$
Système Génerateur	$\gamma_{G1} = 550$ $\gamma_{G2} = 721$ $\gamma_{G3} = 368$
Système d'Entrainement	$\gamma_{DT1} = 685$ $\gamma_{DT2} = 542$ $\gamma_{DT3} = 812$ $\gamma_{DT4} = 623$

TABLE 4.1 – Valeurs des paramètres du MRAC proposé optimisé en appliquant le PSO.

Enfin, cette approche FTC proposée permet de contrôler efficacement toutes les parties du système éolien, même en présence des défauts du processus qui sont très difficiles à traiter. Cependant, l'approche basée sur l'observateur intervalle et les actionneurs / capteurs virtuels proposée dans [**82**] n'est pas sensible aux changements dus au bruit aléatoire et n'est pas capable de contrôler le système à l'instant où le système est affecté par les défauts, ce qui illuste l'amplitude de ces aléas et défauts, comme le montrent les résultats de la simulation suivantes :

4.3 Conclusion

Dans ce chapitre, nous avons présenté une analyse de stabilité rigoureuse utilisant la stratégie de contrôleur adaptative basée sur la commande par modèle de référence et la méthode d'optimisation par essaims particulaires PSO afin de maintenir un fonctionnement optimal du processus même en cas de présence de défauts et de bruit. L'idée générale est que le contrôleur d'éolienne devient comme un servo-contrôleur adaptatif dans lequel les performances souhaitées sont exprimées en forme de modèle de référence, qui donne la réponse souhaitée sous la forme d'un signal de commande optimal même pendant les

différents types des défauts dans les différents composants du système éolien. De plus, la minimisation de la fonction objective de mise en forme d'algorithme d'optimisation par essaims particulaires PSO permet au contrôleur proposé à avoir leur valeur de fonctionnement optimale. Cette proposition est appliquée au système éolien et testé lorsque les différentes types défauts se produisent dans les différentes parties du processus pour avoir l'efficacité, la robustesse et la fiabilité de notre stratégie proposée.

Conclusion et perspectives

L'objectif principal fixé, dans le cadre de cette thèse, était le diagnostic et la commande tolérante aux défauts d'une éolienne, notamment pour leur système de calage de la pâle, leur générateur, leur convertisseur et leur système d'entrainement aussi. Le diagnostic et la commande tolérante aux défauts de ces types de processus complexes demandent une supervision efficace pour avoir un rendement énergétique optimal du système. Par conséquent, les méthodes proposées doivent répondre aux exigences, aux attentes et aux objectifs de la supervision du système éolien parmi lesquels la détection, la localisation et l'identification rapide des défauts capteurs, des défauts actionneurs ou/et des défauts systèmes puis générer l'action corrective puisse reconfigurer le système de commande et puisse accommoder le changement, afin de bénéficier une stabilité, une fiabilité et une sécurité de système éolien, ce qui satisfaisait le bon fonctionnement de système. Dans ce travail, on a détaillé les différentes procédures du diagnostic des capteurs et d'actionneurs et de système. On s'est orienté vers le diagnostic en se basant sur deux catégories : le diagnostic à base de modèle et le diagnostic à base de données (sans modèle). Deux méthodes ont été détaillées pour chaque catégorie de diagnostic à base de modèle et à base de données. Pour le diagnostic à base de modèle, premièrement une architecture de diagnostic comprend un estimateur de détection de panne et un groupe de N estimateurs d'isolement des défauts, ces estimateurs ont considérés pour génerer les résidus, par la suite nous avons proposé une technique de seuillage adaptatif basée sur l'énergie pour l'évaluation des résidus, deuxièment une architecture basée sur l'observateur multi intégrales proportionnelles est dévelopé pour le diagnostic des système éolien, la première partie focalisée sur la modélisation et la commande du système éolien sous leur forme multimodèle, nous développons d'abord l'identification de modèles flous affines du type Takagi-Sugeno, par la suite l'observateur multi intégrales proportionnelles est considéré pour estimer et isoler les différents défauts affectant le système en introduisant ainsi le bruit, avec les défauts actionneurs et capteurs proposés sont à condition que leurs k-dérivées différentes à zéro mais plutôt ont des normes bornées. En outre, pour le diagnostic à base des données, et puisque le problème de diagnostic se transforme dans cet axe de diagnostic, dabord la préparation des données par la définition du vecteur des données x à utiliser pour la classification, ce vecteur doit inclure l'information la plus pertinente du comportement du système relatif à un défaut donné, par la suite deux classificateurs ont été proposés pour classifier les données parmi lesquels le système est défectueux ou non, le premièr classificateur basé sur l'adap-

tation de la machine à vecteurs de support par la logique floue, le deuxième classificateur hybride proposé combine trois approches : algorithme statistique de Bayes, réseaux de neurones à apprentissage de type rétropropagation et l'arbres de décision, tous ces approches ont été combiné à l'aide de la bibliothèque "Environnement de Waikato pour l'analyse des connaissances" (WEKA). Cependant, le problème de la commande tolérante aux défauts (FTC) pour le système éolien a été traité par un contrôleur adaptatif basé sur le principe de commande basant de modèle de référence du modèle et l'algorithme d'optimisation par essaims particulaires "PSO", afin d'atteindre les performances système requises, même lors d'affectations des différents types de défauts et dans les différentes composantes de système éolien, notre proposition se base sur les performances souhaitées lequelles sont exprimées sous la forme d'un modèle de référence, dans lequel l'erreur de comparaison constitue la base du mécanisme d'ajustement des paramètres du contrôleur, et avec l'application de la théorie de la stabilité du Lyapunov, nous avons déterminé les paramètres de contrôleur, en particulier pour le système de calage de la pâle, pour le système générateur et ainsi pour le système d'entrainement d'éolienne, de plus, la minimisation de la fonction objective de mise en forme du PSO permet d'obtenir les paramètres de contrôle optimaux qui bénéficient plus de performances de qualité de conversion d'énergie.

Ces travaux peuvent être poursuivis et affinés par des perspectives pouvant aider à l'améliorer- ration du fonctionnement du dispositif de diagnostic et de commande tolérante aux défauts pour les systèmes en particulier des éoliennes en général. Parmi les perspectives envisageables, on peut prévoir de :

- Établir des méthodes de diagnostic et de commande tolérante aux défauts d'une éolienne, notamment pour l'ensemble de processus soit la partie mécanique et aussi la partie électrique.
- La théorie d'observabilité des entrées inconnues traite seulement le cas d'un seul défaut. D'un point de vue théorique, il nous semble qu'il est maintenaient nécessaire de compléter notre théorie dans le cas de défauts simultanées.
- Une technique de diagnostic combinant les deux familles, à base de modèle et sans modèle, cette combinaison permettant d'exploiter les avantages de chaque famille pour construire une technique de diagnostic qui bénéficie plus de performances de qualité de conversion d'énergie.

Bibliographie

[1] Blanke, M., Kinnaert, M., Lunze, J., Staroswiecki, M., & Schröder, J. (2006). Diagnosis and fault-tolerant control (Vol. 2). Berlin : springer.

[2] Witczak, M. (2007). Modelling and estimation strategies for fault diagnosis of non-linear systems : from analytical to soft computing approaches (Vol. 354). Springer Science & Business Media.

[3] Isermann, R. (2011). Fault-diagnosis applications : model-based condition monitoring : actuators, drives, machinery, plants, sensors, and fault-tolerant systems. Springer Science & Business Media.

[4] Ducard, G. J. (2009). Fault-tolerant flight control and guidance systems : Practical methods for small unmanned aerial vehicles. Springer Science & Business Media.

[5] Witczak, M., & Korbicz, J. (2011). Active fault-tolerant control design for Takagi-Sugeno fuzzy systems. Bulletin of the Polish Academy of Sciences : Technical Sciences, 59(1), 93-102.

[6] Chen, S. X. (1999). Beta kernel estimators for density functions. Computational Statistics & Data Analysis, 31(2), 131-145.

[7] Ripoll, P. (1999). conception d'un système de diagnostic flou appliqué au moteur automobile (Doctoral dissertation, Université Savoie Mont Blanc).

[8] Dubuisson, B. (2001). Diagnostic, intelligence artificielle et reconnaissance des formes. Hermès science publications.

[9] Zwingelstein, G. (1995). Diagnostic des défaillances : théorie et pratique pour les systèmes industriels, traité des nouvelles technologies, éd. hermès.

[10] Frank, P. M., & Köppen-Seliger, B. (1997). New developments using AI in fault diagnosis. Engineering Applications of Artificial Intelligence, 10(1), 3-14.

[11] Isermann, R. (2006). Fault-diagnosis systems : an introduction from fault detection to fault tolerance. Springer Science & Business Media.

[12] Chen, J., & Patton, R. J. (2012). Robust model-based fault diagnosis for dynamic systems (Vol. 3). Springer Science & Business Media.

[13] Patton, R. J., Frank, P. M., & Clark, R. N. (Eds.). (2013). Issues of fault diagnosis for dynamic systems. Springer Science & Business Media.

[14] Combacau, M., Berruet, P., Charbonnaud, F., & Khatab, A. (2000). Réflexions sur la terminologie : Surveillance–Supervision. Groupement pour la recherche en Produtique, Systèmes de Production Sûrs de Fonctionnement.

[15] Chow, E. Y. E. Y., & Willsky, A. (1984). Analytical redundancy and the design of robust failure detection systems. IEEE Transactions on automatic control, 29(7), 603-614.

[16] Gertler, J., & Singer, D. (1990). A new structural framework for parity equation-based failure detection and isolation. Automatica, 26(2), 381-388.

[17] Beard, R. V. (1971). Failure accomodation in linear systems through self-reorganization (Doctoral dissertation, Massachusetts Institute of Technology).

[18] Jones, H. L. (1973). Failure detection in linear systems (Doctoral dissertation, Massachusetts Institute of Technology).

[19] Willsky, A. S. (1976). A survey of design methods for failure detection in dynamic systems. Automatica, 12(6), 601-611.

[20] Travé-Massuyès, L., Dague, P., & Guerrin, F. (1997). Le raisonnement qualitatif pour les sciences de l'ingénieur. Hermes.

[21] Bousson, K., Steyer, J., Travé-Massuyès, L., & Dahhou, B. (1998). From a rule-based to a predictive qualitative model-based approach using automated model generation : Application to the monitoring and diagnosis of biological processes. Engineering Applications of Artificial Intelligence, 11(4), 477-493.

[22] Mosterman, P. J. (2001, March). Diagnosis of physical systems with hybrid models using parametrized causality. In International Workshop on Hybrid Systems : Computation and Control (pp. 447-458). Springer, Berlin, Heidelberg.

[23] Sampath, M., Sengupta, R., Lafortune, S., Sinnamohideen, K., & Teneketzis, D. C. (1996). Failure diagnosis using discrete-event models. IEEE transactions on control systems technology, 4(2), 105-124.

[24] Bhowal, P., Sarkar, D., Mukhopadhyay, S., & Basu, A. (2007). Fault diagnosis in discrete time hybrid systems–a case study. Information Sciences, 177(5), 1290-1308.

[25] Wang, D., Arogeti, S., Zhang, J. B., & Low, C. B. (2008). Monitoring ability analysis and qualitative fault diagnosis using hybrid bond graph. IFAC Proceedings Volumes, 41(2), 10516-10521.

[26] Djeziri, M. A., Bouamama, B. O., & Merzouki, R. (2009). Modelling and robust FDI of steam generator using uncertain bond graph model. Journal of process control, 19(1), 149-162.

[27] Gomaa, M. M. M. (1997). Représentation et supervision des systèmes hybrides par réseaux de Pétri (Doctoral dissertation, Grenoble INPG).

[28] Yassine, F., & Ismail, B. (2017, April). Hybrid classifier for fault detection and isolation in wind turbine based on data-driven. In 2017 Intelligent Systems and Computer Vision (ISCV) (pp. 1-8). IEEE.

[29] Yassine, F., & Ismail, B. (2018). The adaptive fuzzy - support vector machine for fault detection and isolation in wind turbine. International Journal of Engineering Intelligent Systems, 24(3), 1-10.

[30] Gomaa, M. M. M. (1997). Représentation et supervision des systèmes hybrides par réseaux de Pétri (Doctoral dissertation, Grenoble INPG).

[31] Basseville, M. (1988). Detecting changes in signals and systems—a survey. Automatica, 24(3), 309-326.

[32] Zemouri, R. (2003). Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance (Doctoral dissertation, Université de Franche-Comté).

[33] Ondel, O. (2006). Diagnostic par reconnaissance des formes : Application à un ensemble convertisseur-machine asynchrone (Doctoral dissertation, Ecole Centrale de Lyon).

[34] Zwingelstein, G. (1995). Diagnostic des défaillances : théorie et pratique pour les systèmes industriels. Hermès.

[35] Fabbe-Costes, N. (1989). Les systèmes experts de diagnostic technique : Opportunité d'utilisation et contraintes de réalisation. L'Entreprise Logistique, (Hiver 1988-1989), 63-83.

[36] Hongbin, L. I., Zhao, Q., & Yang, Z. (2007). Reliability modeling of fault tolerant control systems. International Journal of Applied Mathematics and Computer Science, 17(4), 491-504.

[37] Patton, R. J. (2015). Fault-tolerant control. Encyclopedia of systems and control, 422-428.

[38] Shen, H., Xu, Y., & Dickinson, B. T. (2014). Fault tolerant attitude control for small unmanned aircraft systems equipped with an airflow sensor array. Bioinspiration & biomimetics, 9(4), 046015.

[39] Mendonça, L. F., Sousa, J. M. C., & da Costa, J. S. (2012). Fault tolerant control using a fuzzy predictive approach. Expert Systems with Applications, 39(12), 10630-10638.

[40] Zhao, Q., & Jiang, J. (1998). Reliable state feedback control system design against actuator failures. Automatica, 34(10), 1267-1272.

[41] Veillette, R. J., Medanic, J. B., & Perkins, W. R. (1992). Design of reliable control systems. IEEE Transactions on Automatic Control, 37(3), 290-304.

[42] Suyama, K. (2002). What is reliable control ?. IFAC Proceedings Volumes, 35(1), 465-470.

[43] Zhang, Y., & Jiang, J. (2006). Issues on integration of fault diagnosis and reconfigurable control in active fault-tolerant control systems. IFAC Proceedings Volumes, 39(13), 1437-1448.

[44] Patton, R. J. (1997). Fault-tolerant control : the 1997 situation. IFAC Proceedings Volumes, 30(18), 1029-1051.

[45] Zhang, Y., & Jiang, J. (2008). Bibliographical review on reconfigurable fault-tolerant control systems. Annual reviews in control, 32(2), 229-252.

[46] Osburn, P. V. (1961). New developments in the design of adaptive control systems. February 1961 Instituteof Aeronautical Sciences, Paper-No.

[47] Ramond, G. (2001). Contribution à la commande prédictive généralisée adaptative directe et applications. le grade de docteur en sciences de l'université Paris Xiorsay.

[48] Schauder, C. (1992). Adaptive speed identification for vector control of induction motors without rotational transducers. IEEE Transactions on Industry Applications, 28(5), 1054-1061.

[49] Stellet, J. E. (2011). Influence of adaptation gain and reference model parameters on system performance for model reference adaptive control. World Academy of Science, Engineering and Technology, 60, 1768-1773.

[50] Vapnik, V. (2013). The nature of statistical learning theory. Springer science & business media.

[51] Vapnik, V. N. (1999). An overview of statistical learning theory. IEEE transactions on neural networks, 10(5), 988-999.

[52] Gunn, S. R. (1998). Support vector machines for classification and regression. ISIS technical report, 14(1), 5-16.

[53] Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In Proceedings of the fifth annual workshop on Computational learning theory (pp. 144-152). ACM.

[54] Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20(3), 273-297.

[55] Zhang, H. (2004). The optimality of naive Bayes. AA, 1(2), 3.

[56] Caruana, R., & Niculescu-Mizil, A. (2006, June). An empirical comparison of supervised learning algorithms. In Proceedings of the 23rd international conference on Machine learning (pp. 161-168). ACM.

[57] Hebb, D. (1949). The Organization of Behavior. emphNew York.

[58] Yassine, F., Kaoutar, L. & Ismail, B. (2017, Décembre). Fault Diagnosis For Wind Turbine System Based On SVM-NN Classifier. Workshop Journéede Recherche Inter-Laboratoire, Fès-Maroc, 22 décembre 2017.

[59] Han, J., Kamber, M., & Pei, J. (2012). Data mining concepts and techniques third edition. Waltham : Elsevier.

[60] Quinlan, J. R. (1986). Induction of decision trees. Machine learning, 1(1), 81-106.

[61] Hunt, E. B., Marin, J., & Stone, P. J. (1966). Experiments in induction.

[62] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). Classification and regression trees (Wadsworth, Belmont, CA). ISBN-13, 978-0412048418.

[63] Zadeh, L. A. (1965). Fuzzy logic and its applications. New York, NY, USA.

[64] Kennedy, J. A. M. E. S. (1995). Eberhart, R. : Particle Swarm Optimization. In Proceedings of IEEE international conference on neural networks (Vol. 4, pp. 1942-1948). IEEE Press.

[65] Clerc, M., & Siarry, P. (2004). Une nouvelle métaheuristique pour l'optimisation difficile : la méthode des essaims particulaires. J3eA, 3, 007.

[66] Tchomté, S. K., & Gourgand, M. (2009). Particle swarm optimization : A study of particle displacement for solving continuous and combinatorial optimization problems. International Journal of Production Economics, 121(1), 57-67.

[67] Mathew, S. (2006). Wind energy : fundamentals, resource analysis and economics (Vol. 1). Berlin : Springer.

[68] Multon, B., Roboam, X., Dakyo, B., Nichita, C., Gergaud, O., & Ahmed, H. B. (2004). Aérogénérateurs électriques. Techniques de l'ingénieur D, 3960, 2004.

[69] Courtecuisse, V. (2008). Supervision d'une centrale multisources à base d'éoliennes et de stockage d'énergie connectée au réseau électrique (Doctoral dissertation, Arts et Métiers ParisTech).

[70] Heier, S. (2002). Grid integration of wind energy conversion systems, 1998. ISBN 0, 471, 97143.

[71] Leclercq, L. (2004). Apport du stockage inertiel associé à des éoliennes dans un réseau électrique en vue d'assurer des services systèmes. university of Lille in France.

[72] Le Gourières, D. (1982). Énergie éolienne : Théorie, conception et calcul pratique des installations. In Energie eolienne : theorie, conception et calcul pratique des installations. Eyrolles.

[73] Lopez, M. (2008). Contribution à l'optimisation d'un système de conversion éolien pour une unité de production isolée (Doctoral dissertation, Université Paris Sud-Paris XI).

[74] Pao, L. Y., & Johnson, K. E. (2009, June). A tutorial on the dynamics and control of wind turbines and wind farms. In American Control Conference, 2009. ACC'09. (pp. 2076-2089). IEEE.

[75] Laverdure, N. (2005). Sur l'intégration des générateurs éoliens dans les réseaux faibles ou insulaires (Doctoral dissertation, Institut National Polytechnique de Grenoble-INPG).

[76] Odgaard, P. F., Stoustrup, J., & Kinnaert, M. (2009, June). Fault tolerant control of wind turbines-a benchmark model. In Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes (Vol. 1, No. 1, pp. 155-160). Barcelona, Spain.

[77] Jonkman, J. M. (2009). Dynamics of offshore floating wind turbines—model development and verification. Wind Energy : An International Journal for Progress and Applications in Wind Power Conversion Technology, 12(5), 459-492.

[78] Matha, D. (2010). Model development and loads analysis of an offshore wind turbine on a tension leg platform with a comparison to other floating turbine concepts : April 2009 (No. NREL/SR-500-45891). National Renewable Energy Lab.(NREL), Golden, CO (United States).

[79] Johnson, K. E., Pao, L. Y., Balas, M. J., & Fingersh, L. J. (2006). Control of variable-speed wind turbines : standard and adaptive techniques for maximizing energy capture. IEEE control systems, 26(3), 70-81.

[80] Merritt, H., Merritt, H. E., & Merritt, H. E. (1967). Hydraulic control systems. John Wiley & Sons.

[81] Odgaard, P. F., Stoustrup, J., & Kinnaert, M. (2013). Fault-tolerant control of wind turbines : A benchmark model. IEEE Transactions on Control Systems Technology, 21(4), 1168-1182.

[82] Blesa, J., Rotondo, D., Puig, V., & Nejjari, F. (2014). FDI and FTC of wind turbines using the interval observer approach and virtual actuators/sensors. Control Engineering Practice, 24, 138-155.

[83] Zhang, X., Polycarpou, M. M., & Parisini, T. (2002). A robust detection and isolation scheme for abrupt and incipient faults in nonlinear systems. IEEE transactions on automatic control, 47(4), 576-593.

[84] Østergaard, K. Z., Brath, P., & Stoustrup, J. (2007). Estimation of effective wind speed. In Journal of Physics : Conference Series (Vol. 75, No. 1, p. 012082). IOP Publishing.

[85] Ding, S. X. (2008). Model-based fault diagnosis techniques : design schemes, algorithms, and tools. Springer Science & Business Media.

[86] Johansson, A., Bask, M., & Norlander, T. (2006). Dynamic threshold generators for robust fault detection in linear systems with parameter uncertainty. Automatica, 42(7), 1095-1106.

[87] Zhang, X., Zhang, Q., Zhao, S., Ferrari, R. M., Polycarpou, M. M., & Parisini, T. (2011, August). Fault detection and isolation of the wind turbine benchmark : An estimation-based approach. In Proceedings of IFAC world congress (Vol. 18, pp. 8295-8300).

[88] Fadili, Y., Lahlou, Z., & Boumhidi, I. (2016, May). An H_∞ TS fuzzy observer-based controller design for wind turbine systems. In 2016 5th International Conference on Systems and Control (ICSC) (pp. 163-168). IEEE.

[89] Zhong, M., Ding, S. X., Lam, J., & Wang, H. (2003). An LMI approach to design robust fault detection filter for uncertain LTI systems. Automatica, 39(3), 543-550.

[90] Yassine F., Kaoutar L. & Ismail B., "Fault Detection and Isolation For Wind Turbine System Based On Proportional Multi-Integral Observer (PMIO)", Accepté le "05 Octobre 2018" à publier dans le journal : "International Journal of Automation and Smart Technology".

[91] Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. IEEE transactions on systems, man, and cybernetics, (1), 116-132.

[92] Castro, J. L. (1995). Fuzzy logic controllers are universal approximators. IEEE transactions on systems, man, and cybernetics, 25(4), 629-635.

[93] Wang, H. O., Tanaka, K., & Griffin, M. (1995, March). Parallel distributed compensation of nonlinear systems by Takagi-Sugeno fuzzy model. In Fuzzy Systems, 1995. International Joint Conference of the Fourth IEEE International Conference on Fuzzy Systems and The Second International Fuzzy Engineering Symposium., Proceedings of 1995 IEEE Int (Vol. 2, pp. 531-538). IEEE.

[94] Duan, G. R., & Yu, H. H. (2013). LMIs in control systems : analysis, design and applications. CRC press.

[95] Gao, Z., Ding, S. X., & Ma, Y. (2007). Robust fault estimation approach and its application in vehicle lateral dynamic systems. Optimal Control Applications and Methods, 28(3), 143-156.

[96] Youssef, T., Chadli, M., Karimi, H. R., & Zelmat, M. (2014). Design of unknown inputs proportional integral observers for TS fuzzy models. Neurocomputing, 123, 156-165.

[97] Rahnavard, M., Yazdi, H., Reza, M., & Ayati, M. (2017). On the development of a sliding mode observer-based fault diagnosis scheme for a wind turbine benchmark model. Energy Equipment and Systems, 5(1), 13-26.

[98] Reiter, R. (1987). A theory of diagnosis from first principles. Artificial intelligence, 32(1), 57-95.

[99] Abe, S. (2005). Support vector machines for pattern classification (Vol. 2, p. 44). London : Springer.

[100] Laouti, N., Sheibat-Othman, N., & Othman, S. (2011). Support vector machines for fault detection in wind turbines. IFAC Proceedings Volumes, 44(1), 7067-7072.

[101] Yassine, F., & Ismail, B., "Fault Tolerant Control For Wind Turbine System Based On Model Reference Adaptive Control And Particle Swarm Optimization Algorithm", Accepté le "04 Avril 2019" à publier dans le journal : " Journal of Circuits, Systems, and Computers".

[102] Askarian, M., Zarghami, R., Jalali-Farahani, F., & Mostoufi, N. (2016). Fault diagnosis of chemical processes considering fault frequency via Bayesian network. The Canadian Journal of Chemical Engineering, 94(12), 2315-2325.

[103] Shah, B., & Trivedi, B. H. (2012). Artificial neural network based intrusion detection system : A survey. International Journal of Computer Applications, 39(6), 13-18.

[104] Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning : A review of classification techniques. Emerging artificial intelligence applications in computer engineering, 160, 3-24.

[105] Yassine, F., & Ismail, B. (2017, Mai). Fault Tolerant Control of Wind Turbine System Based on Model Reference Adaptive Control. Workshop Journéede Recherche Inter-Laboratoire, Fès-Maroc, 17 mai 2017.

[106] Espinoza-Fraire, A. T., Chen, Y., Dzul, A., Lozano, R., & Juarez, R. (2018). Fixed-Wing MAV Adaptive PD Control Based on a Modified MIT Rule with Sliding-Mode Control. Journal of Intelligent & Robotic Systems, 91, 101-114.

[107] Sastry, S., & Bodson, M. (2011). Adaptive control : stability, convergence and robustness. Courier Corporation.

[108] Ioannou, P. A., & Sun, J. (2012). Robust adaptive control. Courier Corporation.